

Локализация и разработка остаточных запасов нефти с использованием геохимических исследований на основе нейросетевых алгоритмов

В.А. Судаков¹, Р.И. Сафуанов¹, А.Н. Козлов^{1*}, Т.М. Порываев¹, А.А. Заикин¹,
Р.А. Зинюков¹, А.А. Лутфуллин², И.З. Фархутдинов², И.З. Туляков²

¹Казанский (Приволжский) федеральный университет, Казань, Россия

²ПАО «Татнефть», Альметьевск, Россия

На поздней стадии разработки месторождений остаточные запасы нефти претерпевают существенное изменение от подвижных до малоподвижных и неподвижных. Эти запасы в основном находятся в техногенно измененных, промытых в процессе эксплуатации, пластах и участках залежей.

Поиск, локализация и разработка таких источников углеводородов является эффективным методом увеличения конечного коэффициента извлечения нефти на зрелых месторождениях, ввиду наличия готовой развитой инфраструктуры добычи, транспортировки и переработки, а также концентрации высококвалифицированных кадров.

В статье рассмотрен подход, позволяющий на основе нейросетевых алгоритмов оценить объемы и локализовать остаточные запасы нефти на многопластовых месторождениях в комплексе с анализом геохимических исследований пластовых флюидов. Использование алгоритмов машинного обучения позволяет адресно подходить к разработке остаточных запасов путем автоматизированного подбора геолого-технических мероприятий. Такой подход значительно сокращает ручной труд специалистов на обработку данных и время принятия решений.

Ключевые слова: программный комплекс, сверточная нейронная сеть, нейросетевые алгоритмы, нефтяное месторождение, локализация запасов нефти, геохимические исследования, подбор геолого-технических мероприятий

Для цитирования: Судаков В.А., Сафуанов Р.И., Козлов А.Н., Порываев Т.М., Заикин А.А., Зинюков Р.А., Лутфуллин А.А., Фархутдинов И.З., Туляков И.З. (2022). Локализация и разработка остаточных запасов нефти с использованием геохимических исследований на основе нейросетевых алгоритмов. *Георесурсы*, 24(4), с. 50–64. <https://doi.org/10.18599/grs.2022.4.4>

Введение

Из-за неоднородности пластов охваченная реальной выработкой толщина пласта в большинстве случаев меньше, чем мощность заводняемого пласта в целом. Пласт, охваченный воздействием заводнения, промывается частично, и после достижения скважиной предельной обводненности заводняемый пласт обычно отключается из разработки. В отключенном из эксплуатации пласте остаются совершенно незатронутые заводнением пропластки, куда еще не проникла вода. В зависимости от неоднородности пласта и технологии разработки в отключенном пласте остается до 50% не вовлеченных в процесс нефтевытеснения пропластков и часть нефти в частично промытых объемах пласта (Муслимов, 2014).

Локализация остаточных запасов на отработанных участках требует полноценного промыслово-геофизического контроля за разработкой залежей, долговременный мониторинг технологических параметров режима работы и постоянное уточнение добычных возможностей скважин. В основе уточненной геологической модели должна быть качественная детальная корреляция в

многопластовых системах, максимально выверенные петрофизические зависимости, что не всегда достижимо по разным причинам. В основном из-за отсутствия исторической информации, недостоверных данных и т.д.

В гидродинамических же моделях не всегда используются косвенные признаки наличия целиков нефти в межскважинном пространстве на основе геохимии, наземной геофизики (tNavigator, Eclipse, Tempest и другие). При этом построение и расчет моделей занимает значительное время.

Как следствие, получаемые результаты распределения остаточных запасов характеризуются неопределенностью (Закревский, 2009).

Таким образом, для получения интегральной картины распределения остаточных запасов логично использовать алгоритмы машинного обучения, искусственные нейронные сети с использованием автоматизированного анализа геолого-промысловых данных и результатов широкого спектра специальных исследований (геохимических, геофизических и т.д.) в единой программной среде.

Также необходимы алгоритмы, которые на основе интерпретации взаимовлияния скважин, будут выдавать точные рекомендации по объему закачки воды в те или иные нагнетательные скважины, подбирать геолого-технические мероприятия на самих скважинах.

Проблема оценки взаимовлияния скважин может быть решена и решается с помощью гидродинамических

* Ответственный автор: Алексей Николаевич Козлов
e-mail: ankozlov.oil@gmail.com

© 2022 Коллектив авторов

Контент доступен под лицензией Creative Commons Attribution 4.0 License (<https://creativecommons.org/licenses/by/4.0/>)

моделей (Степанов и др., 2018). В данной работе рассматривается альтернативный подход, основанный на методах машинного обучения. Разрабатывается стохастический аналог гидродинамической модели, цель которого состоит в вычислении межскважинной проводимости. Такие модели уже используются на практике, например в работах (Aanonsen et al., 2009; Wen, Wen, 2006). Кроме того, настоящая работа развивает более раннюю модель (Zaikin, Salimov, 2019).

Основной причиной использования стохастических методов является то, что гидродинамические модели сильно зависят от качества данных по межскважинной проницаемости (Гладков, Гладкова, 2008), т.е. необходим аутентичный метод их нахождения на основе данных по добыче жидкости. Цель настоящего исследования состоит не в полном физически правдоподобном моделировании потоков жидкости, а лишь в выяснении того, как взаимосвязаны скважины.

Область применения нейронных сетей в нефтяной промышленности обширна: от разведки, бурения до моделирования и разработки месторождений. Например, нейронные сети используются для прогноза кровли пласта во время бурения (Al-Abduljabbar et al., 2018), а при закачке CO_2 в пласты нейросеть используется как инструмент скрининга (Hamam, Ertekin, 2018).

В статье рассматривается способ автоматической интерпретации результатов геохимических исследований, геолого-промысловых данных для динамической оценки остаточных запасов, основанный на применении нейронных сетей.

Для подбора эффективных методов разработки реализован стохастический аналог гидродинамического симулятора с помощью обобщенного фильтра Калмана (Einicke, 2012).

Материалы и методы

Объект

Разработка методик велась на одной из площадей Ромашкинского месторождения.

Основным эксплуатационным объектом площади являются продуктивные отложения кыновского (D_0) и пашийского (D_1) горизонтов нижнефранского подъяруса верхнего девона. Пашийский горизонт является многопластовым объектом. Всего на рассматриваемом объекте 9 пластов (Багманова и др., 2019).

Предварительная обработка данных

Подготовка данных – важный и критичный шаг в нейросетевом моделировании. От того, насколько хорошо подготовлены данные, во многом может зависеть результат использования нейронной сети. Правильная подготовка данных позволяет нейронной сети быстрее и качественнее обучаться и функционировать. Неправильная подготовка данных может сделать анализ сложным или даже невозможным (Костиков и др., 2007).

Исходные данные для нейронной сети представляют собой сетку и кубы начальных свойств из геологической модели, а также геолого-промысловую информацию: месячный эксплуатационный рапорт (МЭР) добывающих и нагнетательных скважин, параметры пробуренных пластов и многое другое. Всего более 100 параметров.

Подготовку данных условно можно разделить на три части:

- обработка и масштабирование исходных свойств кубов геологической модели;
- обработка ошибок записи в геолого-промысловых данных;
- нормализация данных для нейронной сети.

Расчет карт локализации запасов с помощью нейросетевого алгоритма основан прежде всего на данных по добыче и закачке, поэтому по вертикали минимальной единицей нарезки должен служить пласт, для которого эти данные существуют. В нашем конкретном случае это многопластовая залежь, состоящая из 9 пластов (рис. 1).

Для подбора оптимального способа масштабирования исходной геологической сетки по вертикали для расчетов применен опыт моделирования, при котором при вертикальном масштабировании сетки расчет ведется с помощью алгоритма среднего арифметического взвешенного по объему активных ячеек (Кайгородов, 2022).

По латерали размер ячеек обычно ограничивается минимальным расстоянием между скважинами, но поскольку для расчетов передаются данные готовых геологических моделей, настроенных под плотность сетки скважин, программный комплекс оставляет этот параметр без изменения.

Качество рассчитанных результатов напрямую зависит от качества обработки ошибок записей в геолого-промысловых данных (Игнатенко, 2019). Выделяются основные процедуры подготовки данных:

- удаление повторяющихся или недопустимых значений;
- исправление структурных ошибок;
- фильтрация нежелательных отклонений;
- анализ недостающих данных.

Поскольку качество расчетов значительно зависит от характеристик добычи флюида, выполняется автоматический анализ корректности добычи нефти и воды в зависимости от состояния пласта (открыт или закрыт пласт), оценки объемов отбора и закачки по каждому пласту и анализа остаточных запасов не только по площади, но и по разрезу.

Преимущества метода следующие:

- учет архива перфораций, МЭР при сопоставлении с коэффициентом распределения добычи/закачки из производственных баз с автоматическим устранением нестыковок;
- автоматическое использование параметра Kh (проницаемость, умноженная на толщину коллектора), если нет данных о распределении добычи/закачки из производственных баз.




Рис. 1. Вертикальное масштабирование исходной сетки по продуктивным пластам (9 слоев)

Нормализация данных в машинном обучении – это метод предварительной обработки, при котором данные преобразуются для обеспечения равного вклада каждого показателя. Результат обучения зависит от точности описания данных для получения обобщенной прогнозной модели проблемы классификации. Важность нормализации данных для улучшения описания и повышения точности алгоритмов машинного обучения отмечена многими исследователями. Для применения алгоритмов, использующих некую метрику или сравнение данных разных типов, предварительно требуется представление данных в одной шкале измерения (Старовойтов, 2021).

Чаще всего нормализованные данные имеют значения в диапазоне [0;+1]. Если количественные данные описаны в одной шкале с разными интервалами, после нормализации их можно сравнивать и оценивать математически. Фактически нормализация данных – это их преобразование в шкалу частей (Старовойтов, 2021).

Часть исходных данных, например нефтенасыщенность, уже нормализованы, в них автоматически проверяется наличие ошибок. Такие количественные данные, как накопленная добыча нефти и закачка воды, обрабатываются с помощью формулы нормализации min-max (рис. 2).

Нейросетевой прогноз запасов в межскважинном пространстве

Методика предназначена для определения расположения и объема остаточных запасов нефти с помощью машинного обучения. Структура методики состоит из этапов, показанных на рис. 3.

Принцип работы основывается на способности моделей машинного обучения к аппроксимации нелинейных зависимостей с огромным количеством параметров, базирующейся на теореме Цыбенко (Cybenko, 1989). Исходя из этого предполагается, что существует некоторая функция

P , описывающая текущее состояние остаточных запасов в некоторой точке, которая определена и непрерывна на двумерной поверхности заданной территорией месторождения. Из этого следует, что данная функция может быть представлена в виде $P_{x,y} = f(x,y,M)$, где x,y – координаты некоторой точки, M – набор параметров в некоторой точке.

Таким образом, основной задачей локализации остаточных запасов является изучение поведения вышеуказанной функции и установление набора параметров, максимально близко соответствующего тому набору, который в действительности определяет состояние остаточных запасов.

Для решения этой задачи выдвигается гипотеза, что поведение некоторой произвольной точки A может быть определено путем анализа поведения соседних к ней точек с известными характеристиками – скважин (рис. 4).

Понятие «соседства» должно интерпретироваться как «влияние». В данном случае соседними скважинами являются те скважины, которые оказывают максимальное влияние на указанную точку. Обычно, степень влияния обратно пропорциональна расстоянию, поэтому в первом приближении могут быть рассмотрены скважины, геометрически наиболее близкие к рассматриваемой точке, тогда возникает некоторая область с радиусом R .

Исходя из данной схемы, можно предположить, что значение функции P в точке A может быть вычислено на основании анализа доступных данных окружающих её скважин. Если предположить, что вокруг точки A существует m скважин с n характеристиками, то набор M можно установить, как матрицу размера $m \times n$, следовательно, функция P должна осуществлять ряд матричных операций с результирующим значением в виде скаляра (рис. 5). Для этой задачи отлично подходят нейронные сети прямого распространения (Bebis, Georgiopoulos, 1994).

Однако данный подход имеет ряд недостатков. Первый и главный недостаток заключается в необходимости




Рис. 2. Масштабирование (нормализация min-max)

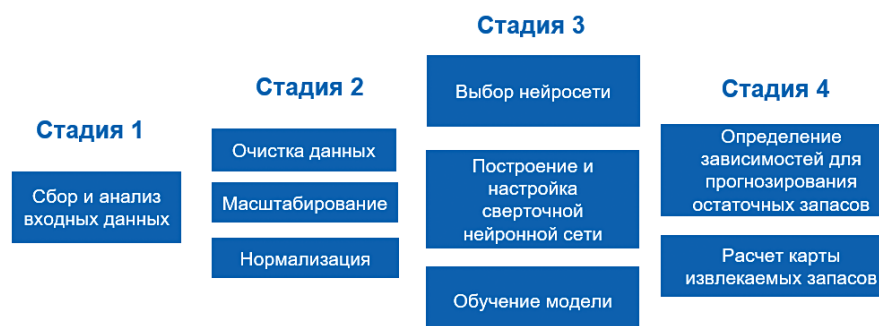


Рис. 3. Структура методики нейросетевого прогноза запасов




Рис. 4. Графическое представление гипотезы

фиксирования числа рассматриваемых соседних скважин, что приводит к потере данных в случае высокой плотности скважин и недостатка данных в случае низкой плотности. Второй недостаток заключается в необходимости неявного вычисления зависимости параметров от положения относительно точки А, т.к. в силу анизотропии пласта различные направления не эквивалентны по своим характеристикам (Семячков, 2009). В большинстве случаев эти зависимости не являются непрерывными и в целом могут не существовать вообще. Визуализация недостатков представлена на рис. 6.

Решить указанные недостатки можно путем перевода задачи из одномерной в двумерную. Так, первоначальную область радиуса R необходимо вписать в квадрат, полученный квадрат необходимо превратить в двумерную сетку путем деления квадрата на множество мелких квадратов. Полученная сетка может быть представлена в виде матрицы, где каждый элемент соответствует ячейке полученной сетки. Далее, в каждый элемент матрицы необходимо записать одно из значений скважины, которая

попадает в соответствующую элементу матрицы ячейку сетки. Таким образом, полученная матрица будет иметь ненулевые элементы в местах включения скважин и нулевые в местах их отсутствия. Данная матрица может быть интерпретирована как изображение в градациях серого, которое может быть проанализировано с помощью сверточной нейронной сети (O’Shea, Nash, 2015). Для каждого параметра необходимо сгенерировать подобную матрицу (рис. 7).

Сверточная нейронная сеть не содержит проблем нейронной сети прямого распространения, т.к. каждая матрица представляет значение и пространственное распределение признака (Rifai et al., 2020; Tan et al., 2019; Liu et al., 2019).

Поведение скважин описывается набором параметров: накопленная добыча нефти, воды и закачка за весь период разработки, пористость, проводимость, нефтенасыщенность приквацинной зоны, забойное давление, а также результатами интерпретации геофизических, геохимических и трассерных исследований.

Недостатком этих параметров является их наличие только в отдельных точках по площади месторождения, то есть при заполнении матрицы она получается разреженной. Несмотря на то, что такой подход все равно работает, он сильно увеличивает время обучения нейросети. Для решения этой задачи необходимо заполнить матрицу в соответствии с некоторыми законами.

Самый простой метод – линейная интерполяция данных. Тем не менее, данный подход не решает первоначальную проблему – неоднородность данных не позволяет проводить корректную линейную интерполяцию (Kidner, 2003).

Другой подход был обнаружен в результате анализа исходных данных – продуктивные параметры в основном распределяются экспоненциально, тогда как фильтрационно-емкостные в основном нормально. Данная закономерность может быть использована для заполнения матрицы




Рис. 5. Нейронная сеть прямого распространения




Рис. 6. Ограничения нейронной сети прямого распространения




Рис. 7. Сверточная нейронная сеть

– каждая матрица заполняется одним из распределений, тем не менее, в силу случайности распределения, результат двух одинаковых расчетов будет совершенно разным. Отсутствие воспроизводимости в данном случае является серьезным недостатком.

Метод, который показал наилучшие результаты – метод интерполяции на основании данных соседних элементов матрицы. В данном случае не создается никаких новых данных, а производится копирование существующих, исходя из концепции, что ячейки вокруг скважины эквивалентны ячейкам самой скважины (Rukundo, 2021).

Полученная матрица, само собой, не отражает реальное состояние пласта, но позволяет значительно ускорить как скорость обучения нейросети, так и минимизировать количество артефактов, возникающих в случае отсутствия данных (рис. 8).

Совокупность полученных матриц представляет собой каналы одного многоканального изображения, которое и




Рис. 8. Способ заполнения разреженной матрицы

анализируется с помощью сверточной нейронной сети (рис. 9).

Рассмотрим распределение признаков на примере участка из 10 скважин, 6 из которых добывающие, 2 нагнетательные, 2 нагнетательные без перфорации на рассматриваемый пласт (рис. 10).

Полученный по вышеуказанной методике тензор был разбит на каналы и окрашен для рассмотрения участка; результат был сглажен для лучшего визуального восприятия. Изображения отражают пространственное распределение признаков. Так, можно видеть, что распространения фронта закачки за период в 1 год происходило не изотропно, а распространялось преимущественно в направлениях Север, Юг, Север-Восток. В свою очередь, добыча нефти как коррелирует с фронтом, так и в меньшей степени зависит от него (рис. 11).

На основании этого можно выдвинуть гипотезу, что между каналами тензора возникает корреляция, которая может быть аппроксимирована путем анализа влияния пространственного распределения признаков друг на друга. Подобная задача может быть решена с применением сверточных нейронных сетей (Li et al., 2019; Zhou et al., 2018; Li et al., 2020).

В качестве обучающего набора данных используется вектор, содержащий накопленные показатели за всю историю разработки: добычу нефти, воды, закачку воды, которые наиболее точно описывают текущее состояние

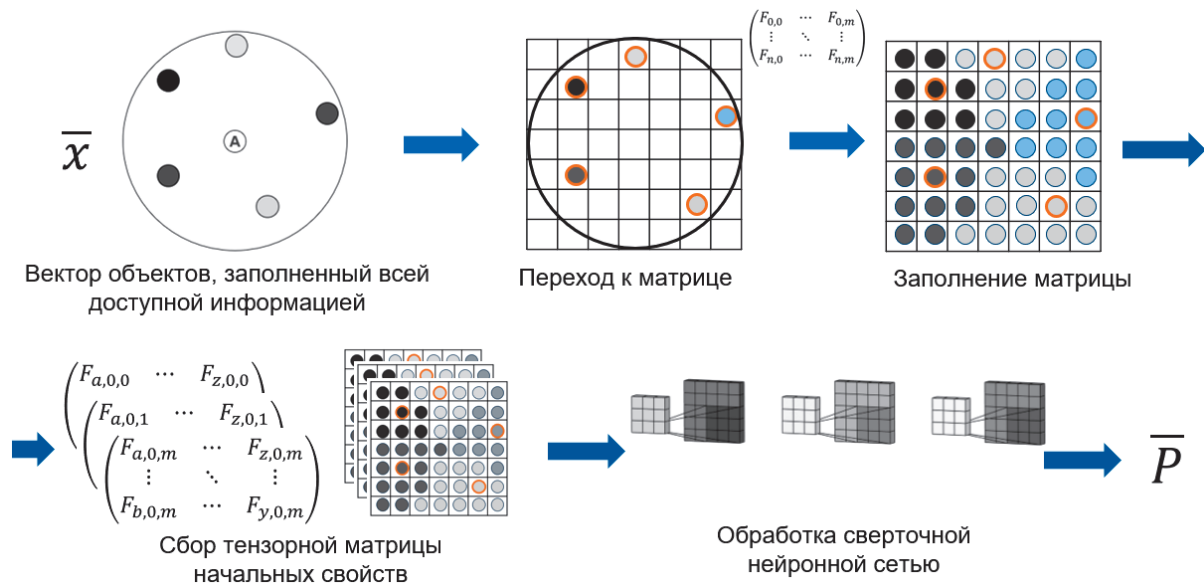


Рис. 9. Получение элемента пласта (матрица) и обработка в сверточной нейронной сети

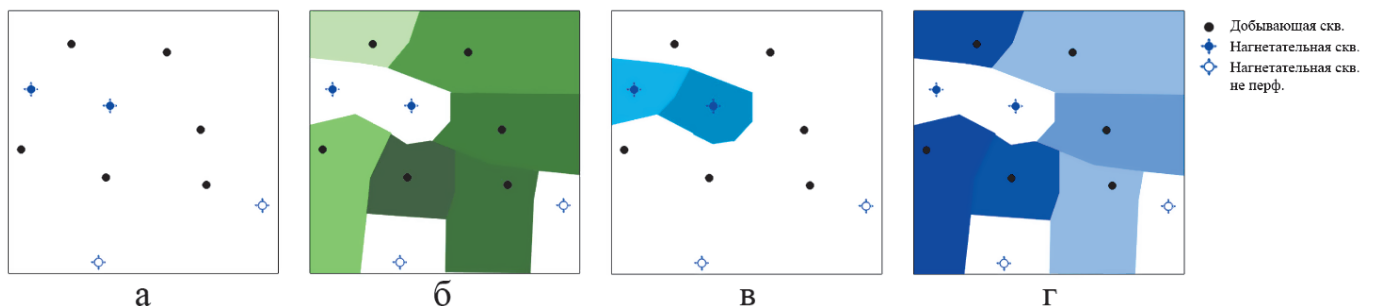


Рис. 10. Визуализация распределения признака на примере участка из 10 скважин. а – геометрическое расположение скважин, б – визуализация признака – «Добытая нефть за 1 год», в – визуализация признака «Закачанная вода за 1 год», z – визуализация признака «Добытая вода за 1 год». Насыщенность цвета отражает размерность признака – чем насыщеннее цвет, тем больше значение.




Рис. 11. Визуализация примерного влияния нагнетательных скважин на добывающие на основании распределения признаков. а – признак «Добыча нефти за 1 год», б – наложение признаков «Добыча воды за 1 год» и «Закачанная вода за 1 год»

пласта. Выбор обусловлен тем, что эти параметры являются непрерывными по времени величинами, варьируются в узком диапазоне от 0 до нескольких тысяч тонн за месяц и имеют корреляцию практически со всеми параметрами скважины. Альтернативным параметром может быть дебит нефти и воды как за текущий, так и за определённый период (Ермолина, Соловьева, 2017).

В качестве функции ошибки используется средне-квадратичная ошибка (MSE), которая применяется для регрессионных задач. Эти потери рассчитываются путем вычисления среднего квадрата разности между фактическими (целевыми) и прогнозируемыми значениями (Toro-Vizcarrondo, Wallace, 1968).

В качестве алгоритма оптимизации используется AdaGrad (Lydia, Francis, 2019), который является разновидностью семейства алгоритмов SGD, использующий адаптивное изменение гиперпараметров модели под каждый признак (рис. 12).

Выходные данные нейронной сети представляют собой вектор длины $3n$ (n – количество слоев), содержащий накопленные показатели: добычу нефти, воды, закачку воды – (P) в каждой ячейке.

Выбор обусловлен тем, что данные по добыче являются наиболее простыми и «естественными» параметрами. Получаемые данные, тем не менее, являются вторичными по отношению к остаточным запасам и лишь косвенно свидетельствуют об их наличии/отсутствии. Мы предполагаем, что, поскольку полученные значения являются количеством жидкости, прошедшей через некоторый объем за фиксированное количество времени, при достаточной длине периода времени и постоянстве объема отношение $\frac{\text{добытая нефть}}{\text{добытая жидкость}}$ будет линейно убывать, из

чего следует, что объем потенциально возможной добычи нефти некоторой ячейки P будет находиться в диапазоне

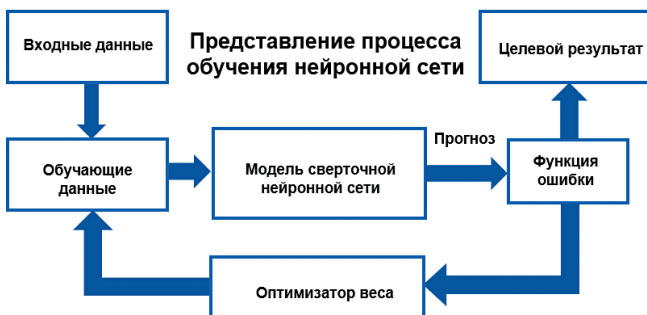


Рис. 12. Процесс обучения

$const * \left(\frac{\text{добытая нефть}}{\text{добытая жидкость}}; 0 \right]$, где константа является

максимальным объемом жидкости, который переместится через данную ячейку за выбранный период. В силу малой линейной скорости фильтрации флюида (Зиновьев и др., 2013; Рыжов и др., 2013; Зайцев и др., 2021), мы предполагаем, что за период времени с момента расчета до конца эксплуатации рассматриваемой области объем фильтрации не превысит поровой объем самой ячейки. Из этого следует, что данное отношение может быть интерпретировано как «нефтенасыщенность». Таким образом, с помощью формулы запасов, используя отношение в каждой ячейке, результат нейросети преобразуется в текущие запасы нефти или воды в ячейке (рис. 13).

$$\begin{aligned} & \begin{pmatrix} \text{Layer } N P_{Cum.oil} \\ \dots \\ \text{Layer } N P_{Cum.water} \\ \dots \end{pmatrix} \\ & \downarrow \\ & \frac{\text{Layer } N P_{oil}}{\text{Layer } N P_{water} + \text{Layer } N P_{oil}} * \text{Porosity Volume} \\ & \downarrow \\ & \begin{pmatrix} \text{Layer } N RES_{oil} \\ \dots \\ \text{Layer } N RES_{water} \\ \dots \end{pmatrix} \end{aligned}$$

Рис. 13. Процесс расчета карты запасов

Методика оптимизации разработки

Программное обеспечение для оптимизации разработки с использованием искусственного интеллекта предназначено для расчета взаимовлияний скважин и автоматического подбора геолого-технических мероприятий (ГТМ).

Для оценки состояния скважин в каждый момент времени реализован стохастический аналог гидродинамического симулятора с использованием обобщенного фильтра Калмана (Ribeiro, 2004). Для прогноза эффективности ГТМ дополнительно используются регрессионные модели.

Структура методики включает следующие этапы (рис. 14):

- оценивается проводимость нефти и воды в межскважинном пространстве, определяются коэффициенты влияния между скважинами;
- на основе локализованных запасов нефти выполняется подбор ГТМ;
- на основе автоматического анализа эффективности ранее выполненных ГТМ определяются потенциальные дебиты нефти планируемых ГТМ.

Преимуществами методики являются самообучаемость, ослабленные требования к адаптации, сокращенное время исполнения алгоритма.

Используются результаты разделения добычи и закачки по пластам. Выполняется разделение каждого пласта на равномерную сетку гексагональных ячеек одинаковой высоты (рис. 15). Каждая ячейка описывается набором переменных (случайных величин) в каждый момент времени. В нашем случае эти переменные представляют



Рис. 14. Структура методики оптимизации разработки

собой количество жидкости и нефтенасыщенность в каждый момент времени (шаг – месяц). Эти величины неизвестны.

Каждая скважина (добывающая или нагнетательная) привязана не к одной ячейке, а к нескольким ближайшим. Несмотря на то, что это предположение не является физическим, оно, тем не менее, заставляет количество жидкости в соседних ячейках быть в некотором смысле зависимым от наблюдаемой добычи. Привязка к ячейкам производится пропорционально расстоянию до их центров от скважины (от точки перфорации).

Добыча нефти $v_m^o(t)$ в момент времени t для скважины m определяется следующим уравнением:

$$v_m^o(t) = \eta_m^o p_m(t) \sum_{n \in so(m)} h_n(t) s_n(t) q_m(n) + \varepsilon_m(t), \quad (1)$$

где $h_n(t)$ и $s_n(t)$ – количество жидкости и нефтенасыщенность для ячейки n в момент времени t , $p_m(t)$ – время работы скважины в момент времени t , η_m^o – неизвестный параметр, связанный только со скважиной, $q_m(n)$ – доля пропорциональности для скважины m относительно ячейки n , $so(m)$ – множество ячеек, связанных со скважиной, $\varepsilon_m(t)$ – неизвестный нормально распределённый белый шум.

Разработка месторождения связана с фильтрационными потоками жидкости в пластах. В описываемом случае из каждой ячейки жидкость перетекает в соседние, и различные жидкости (вода, нефть) имеют различные пропорции перетекания. Значения нефти $o_n(t+1)$ и воды $w_n(t+1)$ в ячейке n определяются следующими уравнениями:

$$o_n(t+1) = h_n(t) s_n(t) + \sum_{n' \in ne(n)} \theta_{n-n'}^o s_n(t) \kappa_o(s_n(t)) (h_{n'}(t) - h_n(t)) - \sum_{m: n \in so(m)} \eta_m^o s_n(t) p_m(t) h_n(t) q_m(n), \quad (2)$$

$$w_n(t+1) = h_n(t) (1 - s_n(t)) + \sum_{n' \in ne(n)} \theta_{n-n'}^w (1 - s_n(t)) \kappa_w(1 - s_n(t)) (h_{n'}(t) - h_n(t)) - \sum_{m: n \in so(m)} \eta_m^w (1 - s_n(t)) p_m(t) h_n(t) q_m(n) + \sum_{l: n \in so(l)} q_l(n) u_l(t) \quad (3)$$

где $ne(n)$ – множество ячеек, соседних к n , $\theta_{n-n'}^w$ и $\theta_{n-n'}^o$ – неизвестные коэффициенты проводимости между ячейками n и n' для воды и нефти, соответственно, $\kappa_w(\cdot)$ и $\kappa_o(\cdot)$ – заранее заданные функции, которые определяют относительную проницаемость соответствующих флюидов при известной насыщенности.

Обновление для скрытых переменных определяется формулами:

$$h_n(t+1) = \text{softplus}(o_n(t+1) + w_n(t+1) + \varepsilon_n^h(t+1))$$

$$s_n(t+1) = \text{sigmoid}\left(\frac{w_n(t+1)}{h_n(t+1)} - \frac{1}{2}\right) \quad (4)$$

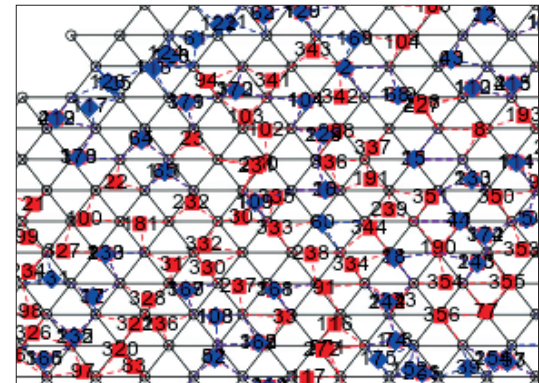


Рис. 15. Гексагональное представление сетки

где $\varepsilon_n^h(t+1)$ – нормально распределённый белый шум.

Эта модель аналогична гидродинамической модели с использованием закона Дарси (например, построения в статье (Чарный, 1963)). С учётом простоты сетки и не привязанности к физическим законам напрямую, она является упрощённой гидродинамической моделью. Эта модель представляет собой частный случай обобщённого фильтра Калмана (Ribeiro, 2004), поскольку нелинейные зависимости в модели представляются в виде, представленном на (рис. 16).


Обучение модели заключается в нахождении такого значения параметров, при которых история разработки лучше всего согласуется с состоянием пласта.

Поскольку в модели присутствуют скрытые переменные, оценка её параметров происходит на основе EM-алгоритма (Barber, 2012).

Алгоритм заключается в чередовании E-шага и M-шага:

- E-шаг заключается в том, что при известных проводимостях жидкости вычисляются объёмы жидкости и нефтенасыщенности в каждый момент времени в каждой ячейке;
- На M-шаге при известном состоянии пласта подбираются проводимости нефти и воды.

Чтобы рассчитать E-шаг, используется ансамблевый фильтр Калмана (Evensen, 1994). Для этого необходимо задание начального распределения жидкости и



- $h(t)$ – состояние пластов в момент времени t
- $v(t)$ – добыча в момент времени t
- T – количество месяцев

Рис. 16. Графическое описание зависимостей в модели

нефтенасыщенности в пласте $h(0), s(0)$. Это производится за счёт данных начального распределения нефтенасыщенности из геологической модели. При расчёте М-шага используется обычный градиентный спуск.

То есть, алгоритм оценивания старается подобрать параметры так, чтобы поведение жидкости в пласте соответствовало истории дебита воды/нефти в каждой скважине (рис. 17). Обучение производится для каждого пласта в отдельности.

Коэффициент влияния вычисляется по следующей формуле:

$$Y(m, l) = (\eta_m^w + \eta_m^o) \sum_{n_1 \in so(l)} \sum_{n_2 \in so(m)} \sum_{y \in ways(n_1, n_2)} q_l(n_1) q_m(n_2) \prod_{a \in y} (\theta_a^w + \theta_a^o) \quad (5)$$

где $ways(n_1, n_2)$ – множество путей кратчайшей длины из ячейки n_1 до ячейки n_2 .

Суть формулы заключается в том, что влияние между двумя скважинами вычисляется как произведение проводимости (в условных единицах) на добычу в период времени и на закачку в этот же период времени. Такая величина характеризует средний объём перекачанной жидкости через пласт.

В случае вычисления по всем пластам итоговый коэффициент влияния получается путём суммирования коэффициентов влияния по каждому пласту. Доля задействованного пласта уже учитывается в силу умножения на объёмы добычи и закачки.

По умолчанию, используется суммарная проводимость нефти и воды $\theta_{n-n}^o + \theta_{n-n}^w$. Однако, для оценки эффективности вытеснения нефти и заводнения можно применять эти коэффициенты по отдельности, таким образом вычисляя коэффициенты взаимовлияния по нефти или воде.

Для удобства работы с результатами происходит нормировка так, чтобы коэффициенты влияния для каждой нагнетательной скважины были равны единице по всем реагирующим добывающим скважинам:

$$Y^*(m, l) = \frac{Y(m, l)}{\sum_m Y(m, l)} \quad (6)$$

Нормировка может проводиться как по направлению от нагнетательных к добывающим скважинам, так и в обратную сторону (рис. 18). Это можно производить как для коэффициентов влияния по проводимости, так и для коэффициентов влияния по жидкости.

Вывод проводимости осуществляется интерполяцией соответствующих величин с гексагональной сетки на

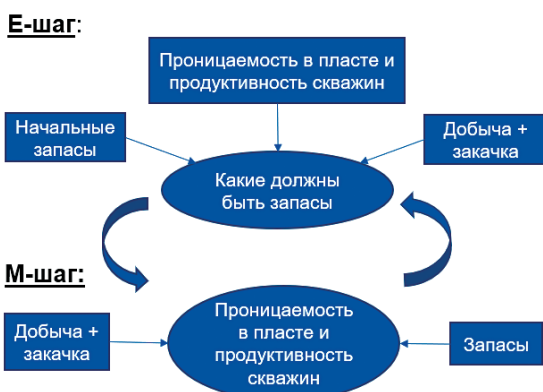


Рис. 17. Графическое представление обучения

квадратную сетку заданной ширины. Например, в точке χ задаётся формулой (7):

$$s(x, t) = \sum_n \frac{1}{A(x)} \exp(-\alpha \|x(n) - x\|^2) s_n(t) \quad (7)$$

где $x(n)$ – координаты ячейки n , $A(x) = \sum_n \exp(-\alpha \|x(n) - x\|^2)$, а параметр $\alpha > 0$.

Таким образом, интерполяция является гауссовым сглаживанием с шириной ядра α^{-1} . Ширина ядра по умолчанию равна половине квадрата расстояния между ячейками сетки.

В качестве координат для выгрузки проводимости θ_{n-n}^o берётся середина границы между соответствующими ячейками, а формула остаётся аналогичной (рис. 19).

Инструмент «Анализ ГТМ» направлен на расчет эффективности ранее проведенных ГТМ и подбор рекомендуемых мероприятий. На основе эффективности ранее проведенных ГТМ (ретроспективный анализ) и текущего состояния разработки с помощью машинного обучения определяется прогнозная дополнительная добыча нефти планируемых ГТМ для конкретных условий любого участка.

Алгоритм ретроспективного анализа использует информацию о выполненных ГТМ, эксплуатационные карточки добывающих и нагнетательных скважин и определяет эффективность каждого ГТМ, проведенного на добывающем и нагнетательном фонде.

Для добывающих скважин расчет эффективности ГТМ выполняется следующим образом (рис. 20):

1. Определяется средний дебит за три месяца до начала ГТМ;
2. Анализируется продолжительность эффекта от ГТМ (до второго пересечения линии m или до планового срока эффекта);
3. Рассчитывается дополнительная добыча нефти как положительная добыча нефти от среднего дебита до ГТМ (сумма добытой нефти выше линии m);
4. Информация о дополнительной добыче от ГТМ формируется в таблицу (табл. 1).




Рис. 18. Пример расчета коэффициентов влияния по жидкости

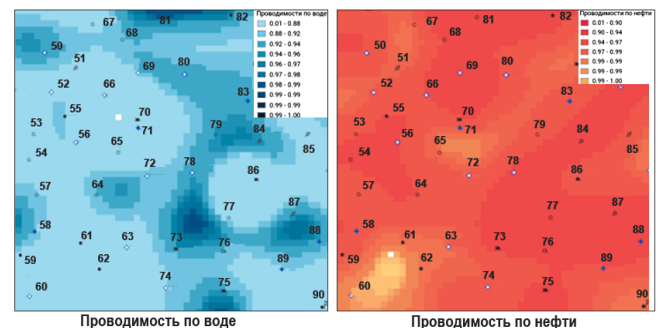


Рис. 19. Пример расчета проводимости по нефти и воде



Рис. 20. Пример расчета для добывающих скважин

Для нагнетательных скважин эффект от ГТМ анализируется следующим образом (рис. 21):

1. Рассчитывается период аппроксимации базовой кривой падения добычи нефти до выполнения ГТМ;
2. Анализируется продолжительность эффекта;
3. Дополнительная добыча считается как положительная добыча нефти от базовой кривой падения добычи нефти. Алгоритм также учитывает разницу между эффектами от ГТМ нагнетательной скважины и реагирующими добывающими скважинами;
4. Информация о дополнительной добычи формируется в таблицу (табл. 2).

Подбор геолого-технических мероприятий производится следующим образом.

Для каждого вида ГТМ на основе заданных критериев выполняется подбор скважин-кандидатов и проектные точки (для бурения новых скважин и боковых стволов). Для скважин-кандидатов вычисляются эксплуатационные характеристики и выводятся в виде аналитических таблиц (рис. 22).

Все критерии автоматизированы и сконфигурированы таким образом, чтобы специалист с минимальным вмешательством имел возможность формировать ГТМ на рассматриваемом участке.

Для подбора точек бурения и забуривания боковых стволов по всей площади равномерно распределяется большое количество точек. Для каждой точки вычисляются запасы и нефтенасыщенность в ячейке Вороного, построенной по множеству скважин и этой проектной точке, и пересечённой с кругом заданного радиуса. После вычисления всех характеристик точки фильтруются согласно критериям. Среди отфильтрованных точек последовательно отбираются точки с наибольшими суммарными запасами по всем пластам так, чтобы точки находились не ближе, чем на определённом расстоянии друг от друга (рис. 23).




Рис. 21. Пример расчета для нагнетательных скважин

N скв.	Катег скв после ГТМ	ГТМ укруп.	Наимен ГТМ	Дата начала ГТМ	Дата окончания ГТМ	Среднее 3 мес до ГТМ			Среднее 3 мес сразу после ГТМ			Период действия, мес	Накопленная добыча, тонн		
						Ож, т/сут	Ож, т/сут	% обв	Ож, т/сут	Ож, т/сут	% обв				
70	НЕФ	Физико-химические методы ОПЗ	Акустико-химическое возд. (АХВ)	22.01.2001	22.01.2001	0,57	0,06	2,63	0,76	0,11	4,52	0,79	0,22	9,42	46,49
40	НЕФ	Водо-изоляционные работы и ремонтно-изоляционные работы	Биополимер	12.05.1997	12.05.1997	0,25	2,44	87,46	0,53	8,46	92,38	0,15	3,24	94,07	15,42
64	НЕФ	Водо-изоляционные работы и ремонтно-изоляционные работы	Водные эмульсионно-суспензионные системы (ВЭСС)	29.09.2002	01.10.2002	3,2	68,4	95,53	6,15	75,67	92,4	6,25	59,8	90,21	1264,67

Табл. 1. Пример расчетов для добывающих скважин

Нагн.скв.	Пласты	Q ₃ мес. ср. до, м3/сут	Q ₃ мес. ср. после, м3/сут	ГТМ укрупн.	Тип анализа	Дата оконч ГТМ	Дата пуска нагн.скв	Дата начала расчета ДДН нагн.скв	Период эффекта расч, мес	Накоп. добыча, тонн	Окруж.Д обыв кв	Квл	Пласт	Qн_ф до, т/сут	Qж_ф до, м3/сут	Обв_ф до	Qн_ф после, т/сут	Qж_ф после, м3/сут	Обв_ф после
XXXXXX	Д1Г1, Д1Г2+3, Д1Д	0,2	0,2	МУН (потокоотклоняющие)	по дебиту	2010-08-17	09.2010	2010-10-01	27	10452	XXXXXX	0,91	Д1Г2+3, Д1Д	1,1	1,3	15	10,9	21,7	50
XXXXXX	Д1А, Д1Б3, Д кынов.	0	0	Гидроразрыв пласта	по дебиту	2014-12-10	12.2014	2015-01-01	87	553	XXXXXX	0,19	Д1Д	0,2	8,5	97	0,2	8,6	97
XXXXXX	Д кынов.	0,1	0,1	Водо-изоляционные работы и ремонтно-МУН	по дебиту	2011-11-26	01.2012	2012-02-01	9	69	XXXXXX	0,95	Д кынов.	4,4	5,2	15	4,2	5	16
XXXXXX	Д1Б3, Д кынов.	3,5	2,8	МУН (потокоотклоняющие)	по дебиту	2021-03-18	04.2021	2021-05-01	16	2231	XXXXXX	0,93	Д1А, Д1Б2, Д кынов.	4,2	5,1	18	3,1	3,8	19
XXXXXX	Д1А	0	0	Переводы на другой объект	по дебиту	2010-02-28	08.2012	2012-09-01	23	3664	XXXXXX	0,78	Д1А, Д1Б1	0,4	0,7	49	0,4	0,5	31
XXXXXX	Д1Б1, Д кынов.	0	0,4	Физико-химические методы ОПЗ	по дебиту	2018-07-25	08.2018	2018-09-01	1	99	XXXXXX	0,09	Д1А, Д1В, Д кынов.	0,2	0,5	58	0,2	0,5	53
XXXXXX											XXXXXX	0,91	Д1Г1, Д кынов.	3,5	13,2	73	4,8	62	92

Табл. 2. Пример расчетов для насметательных скважин

В аналитических таблицах для скважин-кандидатов представлены наиболее востребованные данные для принятия решений: ФЕС, запасы нефти, объемы закаченной воды, доля воды в пласте, режим работы скважин и т.п.

Прогноз эффективности ГТМ (прирост дебита нефти и жидкости, продолжительность эффекта) выполняется различным образом для разных типов ГТМ.

Для бурения новых скважин и забуривания боковых стволов прогнозируемый дебит нефти и жидкости вычисляется нейросетевым алгоритмом.

Для остальных видов ГТМ разрабатывается регрессионная модель для нахождения суммарной дополнительной добычи, периода эффекта и вероятности успеха ГТМ. Под успехом ГТМ понимается факт положительности дополнительной добычи нефти. В качестве входных данных для этой регрессионной модели используются параметры и характеристики обученной модели (фильтр Калмана), геолого-промысловые данные за период, предшествующий планируемому ГТМ.

Результаты и обсуждение

Методика подтверждения наличия локализованных запасов нефти из программного комплекса основана на изучении естественных маркеров процесса биодegradации углеводородов в залежах (рис. 24), интенсивно протекающего в зонах контакта нефти и нагнетаемой воды, но не затрагивающего невыработанные зоны, что приводит к появлению различий в составе флюида в промытой и застойной зонах (Minmin Cai et al., 2015). Методология предусматривает создание системы мониторинга изменения компонентного состава углеводородов с целью локализации участков, характеризующихся меньшей величиной биодegradации. Такие участки могут быть рассмотрены в качестве зон наиболее вероятного нахождения остаточных запасов (Novikova et al., 2020).

Общеизвестно, что одним из первых признаков биодegradации является уменьшение содержания и исчезновение лёгких n-алканов. В процессе разработки отношение тяжелых компонентов к легким увеличивается в ходе интенсивной биодegradации углеводородов в залежах. Поскольку бактерии обитают на границе воды и нефти, в зонах, откуда добывается нефть, здесь это отношение очень быстро растет за счет все большего увеличения площади контакта воды и нефти (Nurgaliev, 2006). В части залежи, не затронутой процессом заводнения, это отношение остается на первичном уровне, таким образом формируется неоднородное распределение этого отношения внутри залежи. Это явление может быть использовано для оценки наличия застойных не дренируемых зон, их объемов и степени вовлечения их в разработку (Nurgaliev et al., 2021).

В качестве исходных данных могут быть рассмотрены результаты анализа компонентного состава попутного газа. В ходе регистрации изменения компонентного состава в моменты геодинамических возмущений может быть локализовано местоположение невыработанной зоны, находящейся в пределах радиуса дренирования скважины, в которой была отобрана «аномальная» проба.

Сравнение карты запасов нефти и результатов мониторинга ПНГ показало (рис. 25) следующее:

№	Скважина	X	Y	Пласт	Толщина, м	Пористость, %	Глинистость, ед	Доля воды в пласте в R-200 м, д.ед	Запасы нефти в пласте в R-200, т	Общие запасы нефти в R-200, т	Прогнозный дебит нефти, т/сут	Прогнозный дебит жидкости, т/сут	Прогнозная обводненность, %	
1				Д1А	1.02	18,77	4,32	0,52	1959,15	326341,35	0,84	1,66	50	
				Д1Б1	3.89	20,4	4,99	0,18	28,54		12,05	21,39	44	
				Д1Б2	Не коллектор									
				Д1Б3	Не коллектор									
				Д1В	3.09	24	0,46	0,43	56392,33		1,02	1,98	48	
				Д1Г1	3.23	21,94	0,2	0,45	74077,72		0,78	1,47	47	
				Д1Г2+3	11.67	22,69	1,01	0,42	94065,5		0,91	1,7	47	
				Д1Д	5.79	22,47	1,68	0,81	25449,93		2,88	18,12	84	
			Д кынов.	2.08	20,39	2,79	0,12	53579,98	38,81	40,85	5			
2				Д1А	Не коллектор					280571,21				
				Д1Б1	2.87	20,9	2,31	0,13	3219,06		1409,75	1617,02	13	
				Д1Б2	0.94	21,06	1,16	0,51	18631,4		38,67	54,55	29	
				Д1Б3	Не коллектор									
				Д1В	4.47	21,52	0,46	0,46	44092,69		670,85	1066,01	37	
				Д1Г1	7.09	21,46	0,18	0,42	66912,46		2,28	3,88	41	
				Д1Г2+3	10.54	21,14	0,41	0,43	74810,26		7	13,27	47	
				Д1Д	7.89	20,4	0,67	0,75	27479,04		10,17	43,32	77	
			Д кынов.	4.28	18,59	1,69	0,14	42282,06	27,47	30,73	11			

Рис. 22. Пример представления расчетных данных для точек бурения скважин и БС

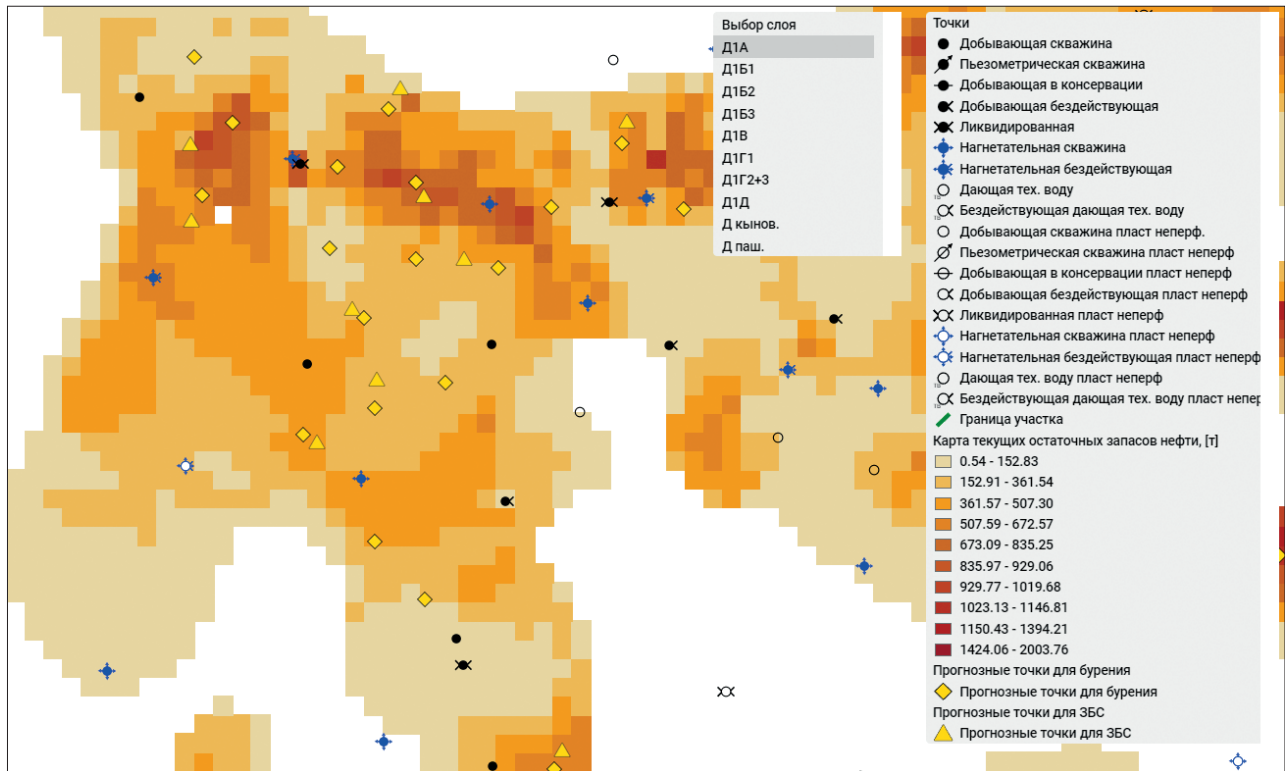


Рис. 23. Пример подбора точки бурения (ромб) и боковых стволов (треугольник) по данным локализованных запасов и текущему состоянию разработки участка




Рис. 24. Графическое представление процесса биодegradации углеводородов

- Зоны с локализованными запасами расположены в зоне аномалий, полученных в результате геохимических исследований;
- Аномалии указывают на наличие зон с высокой плотностью запасов, соответственно, в областях без аномалий алгоритм нейросети локализует запасы в небольших объемах.

Заключение

В статье рассмотрен подход, позволяющий на основе нейросетевых алгоритмов оценить объемы и локализовать

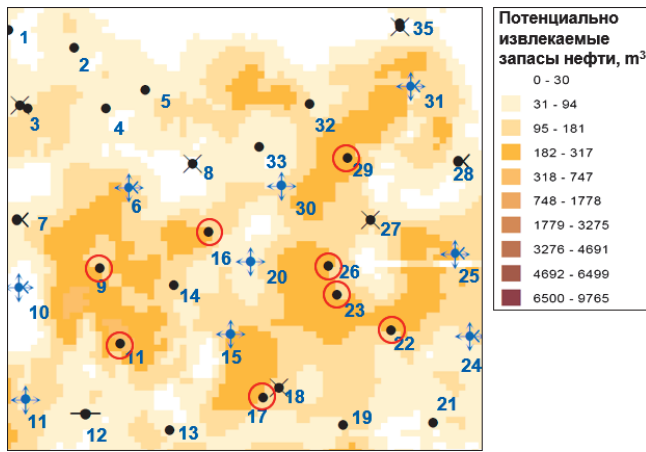


Рис. 25. Сравнение расчетов с результатами геохимического анализа

остаточные запасы нефти на многопластовых месторождениях, наличие которых подтверждается с помощью анализа изменения компонентного состава попутного газа.

Для оптимизации процесса разработки представлена методика, по которой оценивается аналог проводимости нефти и воды в межскважинном пространстве, определяются коэффициенты влияния между скважинами. Затем на основе ФЭС скважин и локализованных запасов нефти выполняется подбор ГТМ. Благодаря автоматическому анализу эффективности ранее выполненных ГТМ определяются потенциальные дебиты нефти планируемых ГТМ.

Автоматизация процесса отбраковки данных, анализа взаимовлияния скважин, подбора ГТМ дает возможность оптимизировать ручной труд специалистов и снизить время на обработку данных.

На сегодняшний день совместно с ПАО «Татнефть» определен потенциальный фонд скважин-кандидатов, на которых планируется выполнить ГТМ за счет внедрения технологии.

Финансирование/Благодарности

Работа выполнена при поддержке Минобрнауки России в рамках соглашения № 075-15-2022-299 о предоставлении гранта в форме субсидий из федерального бюджета на осуществление государственной поддержки создания и развития научного центра мирового уровня «Рациональное освоение запасов жидких углеводородов планеты»

Авторы выражают благодарность рецензентам за проделанную работу, высказанные замечания и рекомендации, которые позволили улучшить статью.

Литература

- Багманова С.В. и др. (2019). Геология Волго-Уральской нефтегазовой провинции. Оренбург: ОГУ, 127 с.
- Гладков Е.А., Гладкова Е.Е. (2008). Неоднозначность геолого-технологической информации в процессе адаптации гидродинамической модели. *Бурение и нефть*, 10, с. 40–41.
- Ермолина А.В., Соловьева А.В. (2017). Характеристика факторов, влияющих на нефтеотдачу пласта. *Геология, география и глобальная энергия*, 4, с. 43–48.
- Зайцев М.В., Михайлов Н.Н., Туманова Е.С. (2021). Модели нелинейной фильтрации и влияние параметров нелинейности на дебит скважин в низкопроницаемых коллекторах. *Георесурсы*, 23(4), с. 44–50. <https://doi.org/10.18599/grs.2021.4.5>

Закревский К.Е. (2009). Геологическое 3D моделирование. Москва: ООО ИПЦ Маска, 376 с.

Зиновьев А.М. и др. (2013). Исследование реологических свойств и особенностей фильтрации высоковязких нефтей месторождений Самарской области. *Вестник Самарского государственного технического университета. Серия: Технические науки*, 2, с. 197–205.

Игнатенко А.М., Макарова И.Л., Копырин А.С. (2019). Методы подготовки данных к анализу слабоструктурированных временных рядов. *Программные системы и вычислительные методы*, 4, с. 87–94. <https://doi.org/10.7256/2454-0714.2019.4.31797>

Кайгородов С.В. (2022). Типичные ошибки при создании гидродинамических моделей. Часть I. Ремасштабирование геологической модели. *ПРОНЕФТЬ. Профессионально о нефти*, 2, с. 52–58.

Костиков Д.В., Петров А.Н., Лялин В.Е. (2007). Подготовка исходных данных для задачи интерпретации геофизических исследований скважин с помощью многослойной нейронной сети. *Труды Международного симпозиума «Надежность и качество»*, т. 1, с. 123–128.

Муслимов Р.Х. (2012). Нефтеотдача: прошлое, настоящее, будущее. Казань: Фэн, 663 с.

Рыжов А.Е. и др. (2013). Физическое и математическое моделирование многофазной фильтрации при проектировании разработки нефтяной оторочки Ен-Яхинского НГКМ. *Вести газовой науки*, 1(12), с. 126–137.

Семячков А.И. (2009). Фильтрационная неоднородность трещиноватых пород. Москва: Горная книга, 151 с.

Старовойтов В.В., Голуб Ю.И. (2021). Нормализация данных в машинном обучении. *Информатика*, 18(3), с. 83–96. <https://doi.org/10.37661/1816-0301-2021-18-3-83-96>

Степанов С.В., Соколов С.В., Ручкин А.А., Степанов А.В., Князев А.В., Корытов А.В. (2018). Проблематика оценки взаимовлияния добывающих и нагнетательных скважин на основе математического моделирования. *Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика*, 4(3), с. 146–164. <https://doi.org/10.21684/2411-7978-2018-4-3-146-164>

Чарный И.А. (1963). Подземная гидрогазодинамика. Москва: Гостоптехиздат, 397 с.

Aanonsen, Sigurd I., Geir Nævdal, Dean S. Oliver, Albert C. Reynolds, and Brice Vallès (2009). The ensemble Kalman filter in reservoir engineering – a review. *SPE J*, 14(3), pp. 393–412. <https://doi.org/10.2118/117274-PA>

Al-Abduljabbar A. et al. (2018). Predicting formation tops while drilling using artificial intelligence. *SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition*. <https://doi.org/10.2118/192345-MS>

Barber D. (2012). Bayesian reasoning and machine learning. Cambridge University Press, p. 610. <https://doi.org/10.1017/CBO9780511804779>

Bebis G., Georgiopoulos M. (1994). Feed-forward neural networks. *IEEE Potentials*, 13(4), pp. 27–31. <https://doi.org/10.1109/45.329294>

Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of control, signals and systems*, 2(4), pp. 303–314. <https://doi.org/10.1007/BF02551274>

Einicke G.A. (2012). Smoothing, Filtering and Prediction: Estimating the Past, Present and Future. Rijeka, Croatia: Intech, 286 p.

Evensen G. (1994). Sequential data assimilation with a non-linear quasi-geostrophic model using Monte Carlo methods to forecast error statistics. *J Geophys Res*, 99(C5), pp. 10143–10162. <https://doi.org/10.1029/94JC00572>

Hamam H., Ertekin T.A. (2018). Generalized varying oil compositions and relative permeability screening tool for continuous carbon dioxide injection in naturally fractured reservoirs. *SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition*. <https://doi.org/10.2118/192194-MS>

Kidner D.B. (2003). Higher-order interpolation of regular grid digital elevation models. *International Journal of Remote Sensing*, 24(14), pp. 2981–2987. <https://doi.org/10.1080/0143116031000086835>

Li S., Chen J., Xiang J. (2020). Applications of deep convolutional neural networks in prospecting prediction based on two-dimensional geological big data. *Neural computing and applications*, 32(7), pp. 2037–2053. <https://doi.org/10.1007/s00521-019-04341-3>

Liu B., Li Y., Li G., & Liu A. (2019). A spectral feature based convolutional neural network for classification of sea surface oil spill. *ISPRS International Journal of Geo-Information*, 8(4), p. 160. <https://doi.org/10.3390/ijgi8040160>

Lydia A., Francis S. (2019). Adagrad – an optimizer for stochastic gradient descent. *Int. J. Inf. Comput. Sci.*, 6(5), pp. 566–568.

Minmin Cai, Nùria Jiménez, Martin Krüger, Huan Guo, Yao Jun, Nontje Straaten, Hans H. Richnow (2015). Potential for aerobic and methanogenic oil biodegradation in a water flooded oil field (Dagang oil field). *Fuel*, 141, pp. 143–153. <https://doi.org/10.1016/j.fuel.2014.10.035>

Novikova S., Rizvanova Z., Ziniukov R., Usmanov S. (2020). Prospects of geochemical monitoring on the basis of borehole oil samples at bypassed

oil reserves localization. *Int. Multidis. Sci. GeoConf. SGEM*, pp. 739–744. <https://doi.org/10.5593/sgem2020/1.2/s06.094>

Nurgaliev D., Ziniukov R., Sudakov V., Fakhriev, N., Averyanov A. (2021). Evaluation of the applicability of biodegradation Markers for identification of the bypassed oil zones. *21st Int. Multidis. Sci. GeoConf. SGEM*, pp. 935–941. <https://doi.org/10.5593/sgem2021/1.1/s06.113>

Nurgaliev et al. (2006). Variation of i-butane/n-butane ratio in oils of the Romashkino oil field for the period of 1982–2000: Probable influence of the global seismicity on the fluid migration. *Journal of Geochemical Exploration*, 89(1–3), pp. 293–296. <https://doi.org/10.1016/j.gexplo.2005.12.022>

O'Shea K., Nash R. (2015). An introduction to convolutional neural networks. arXiv preprint arXiv:1511.08458.

Ribeiro M.I. (2004). Kalman and extended kalman filters: Concept, derivation and properties. Institute for Systems and Robotics, 46 p.

Rifai A.P., Aoyama H., Tho N.H., Dawal S.Z.M., Masruroh N.A. (2020). Evaluation of turned and milled surfaces roughness using convolutional neural network. *Measurement*, 161, 107860. <https://doi.org/10.1016/j.measurement.2020.107860>

Rukundo O. (2021). Evaluation of Rounding Functions in Nearest Neighbor Interpolation. *International Journal of Computational Methods*, 18(08), 2150024. <https://doi.org/10.1142/S0219876221500249>

Ta, J., Li S., Chen J., Liu C., Wang Y. (2021). Mineral prospectivity prediction via convolutional neural networks based on geological big data. *Journal of Earth Science*, 32(2), pp. 327–347. <https://doi.org/10.1007/s12583-020-1365-z>

Tan J., NourEldeen N., Mao K., Shi J., Li Z., Xu T., Yuan Z. (2019). Deep learning convolutional neural network for the retrieval of land surface temperature from AMSR2 data in China. *Sensors*, 19(13), 2987. <https://doi.org/10.3390/s19132987>

Toro-Vizcarrondo C., Wallace T.D. (1968). A test of the mean square error criterion for restrictions in linear regression. *Journal of the American Statistical Association*, 63(322), pp. 558–572. <https://doi.org/10.1080/01621459.1968.11009275>

Wen Xian-Huan, and Wen H. Chen (2006). Real-time reservoir model updating using ensemble Kalman filter with confirming option. *SPE J.*, 11(04), pp. 431–442. <https://doi.org/10.2118/92991-PA>

Zaikin A., Salimov R. (2019). An application of Kalman filter model to reservoir pressure maintenance. *Int. Multidis. Sci. GeoConf. SGEM*, (1.2), pp. 627–634. <https://doi.org/10.5593/sgem2019/1.2/S06.079>

Zhou, Zhuang, Shengyang Li, and Yuyang Shao (2018). Crops classification from sentinel-2A multi-spectral remote sensing images based on convolutional neural networks. *IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium*. <https://doi.org/10.1109/IGARSS.2018.8518860>

Сведения об авторах

Владислав Анатольевич Судаков – заместитель директора института по инновационной деятельности, директор НОЦ «Моделирование ТРИЗ», Институт геологии и нефтегазовых технологий, Казанский (Приволжский) федеральный университет

Россия, 420111, Казань, ул. Большая Красная, д. 4

Ринат Иолдузович Сафуанов – научный сотрудник НОЦ «Моделирование ТРИЗ», Институт геологии и нефтегазовых технологий, Казанский (Приволжский) федеральный университет

Россия, 420111, Казань, ул. Большая Красная, д. 4

Алексей Николаевич Козлов – младший научный сотрудник НОЦ «Моделирование ТРИЗ», Институт геологии и нефтегазовых технологий, Казанский (Приволжский) федеральный университет

Россия, 420111, Казань, ул. Большая Красная, д. 4

Тимур Маратович Порываев – инженер НОЦ «Моделирование ТРИЗ», Институт геологии и нефтегазовых технологий, Казанский (Приволжский) федеральный университет

Россия, 420111, Казань, ул. Большая Красная, д. 4

Артем Александрович Заикин – научный сотрудник НОЦ «Моделирование ТРИЗ», Институт геологии и нефтегазовых технологий, Казанский (Приволжский) федеральный университет

Россия, 420111, Казань, ул. Большая Красная, д. 4

Рустам Анверович Зинюков – младший научный сотрудник НОЦ «Моделирование ТРИЗ», Институт геологии и нефтегазовых технологий, Казанский (Приволжский) федеральный университет

Россия, 420111, Казань, ул. Большая Красная, д. 4

Азат Абузарович Лутфуллин – заместитель начальника департамента разработки месторождений СП «Татнефть-Добыча», ПАО «Татнефть»

Россия, 423450, Альметьевск, ул. Ленина, д. 75

Ильдар Зуфарович Фархутдинов – начальник отдела разработки нефтяных и газовых месторождений и геологоразведочных работ Центра технологического развития, ПАО «Татнефть»

Россия, 423462, Альметьевск, ул. Тельмана, д. 88

Ильгиз Зуфарович Туляков – ведущий эксперт отдела разработки нефтяных и газовых месторождений и геологоразведочных работ Центра технологического развития, ПАО «Татнефть»

Россия, 423462, Альметьевск, ул. Тельмана, д. 88

Статья поступила в редакцию 20.09.2022;

Принята к публикации 10.11.2022;

Опубликована 20.12.2022

IN ENGLISH

ORIGINAL ARTICLE

Localization and development of residual oil reserves using geochemical studies based on neural network algorithms

V.A. Sudakov¹, R.I. Safuanov¹, A.N. Kozlov¹, T.M. Poryvaev¹, A.A. Zaikin¹, R.A. Zinyukov¹,
A.A. Lutfullin², I.Z. Farkhutdinov², I.Z. Tylyakov²

¹Kazan Federal University, Kazan, Russian Federation

²Tatneft PJSC, Almet'yevsk, Russian Federation

*Corresponding author: Aleksey N. Kozlov, e-mail: ankozlov.oil@gmail.com

Abstract. At the late stage of field development, residual oil reserves undergo a significant change from mobile to sedentary and stationary. These reserves are mainly located in technogenically and production altered, watered layers and areas of deposits.

Localization and development of such sources of hydrocarbons is an effective method of increasing the final oil recovery factor in mature fields, due to the presence of a ready-made developed infrastructure for production, transportation and refining, as well as the availability of highly qualified personnel.

This article considers an approach that allows, based on neural network algorithms, the estimation the volumes and localization of residual oil reserves in multi-layer deposits in combination with the analysis of geochemical studies of reservoir fluids. The use of machine learning algorithms allows a targeted approach to the development of residual reserves by automated selection of wellwork. This approach significantly reduces the manual labor of specialists for data processing and decision-making time.

Keywords: software package, convolutional neural network, neural network algorithms, oil field, localization of oil reserves, geochemical studies, selection of geological and technical measures

Acknowledgements

This work was supported by the Ministry of Science and Higher Education of the Russian Federation under agreement No. 075-15-2022-299 within the framework of the development program for a world-class Research Center “Efficient development of the global liquid hydrocarbon reserves”.

The authors are grateful to the reviewers for the comments and recommendations that made it possible to improve the article.

Recommended citation: Sudakov V.A., Safuanov R.I., Kozlov A.N., Poryvaev T.M., Zaikin A.A., Zinyukov R.A., Lutfullin A.A., Farkhutdinov I.Z., Tylyakov I.Z. (2022). Localization and development of residual oil reserves using geochemical studies based on neural network algorithms. *Georesursy = Georesources*, 24(4), pp. 50–64. <https://doi.org/10.18599/grs.2022.4.4>

References

- Aanonsen, Sigurd I., Geir Nævdal, Dean S. Oliver, Albert C. Reynolds, and Brice Vallès (2009). The ensemble Kalman filter in reservoir engineering – a review. *SPE J*, 14(3), pp. 393–412. <https://doi.org/10.2118/117274-PA>
- Al-AbdulJabbar A. et al. (2018). Predicting formation tops while drilling using artificial intelligence. *SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition*. <https://doi.org/10.2118/192345-MS>
- Bagmanova S.V. et al. (2019). Geology of the Volga-Ural oil and gas province. Orenburg: OGU, 127 p. (In Russ.)
- Barber D. (2012). Bayesian reasoning and machine learning. Cambridge University Press, p. 610. <https://doi.org/10.1017/CBO9780511804779>
- Bebis G., Georgiopoulos M. (1994). Feed-forward neural networks. *IEEE Potentials*, 13(4), pp. 27–31. <https://doi.org/10.1109/45.329294>
- Charnyi I.A. (1963). Underground hydrodynamics. Moscow: Gostoptekhizdat, 397 p. (In Russ.)
- Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of control, signals and systems*, 2(4), pp. 303–314. <https://doi.org/10.1007/BF02551274>
- Einicke G.A. (2012). Smoothing, Filtering and Prediction: Estimating the Past, Present and Future. Rijeka, Croatia: Intech, 286 p.
- Ermolina A.V., Solovieva A.V. (2017). Characterization of the factors influencing the oil recovery of the formation. *Geologiya, geografiya i global'naya energiya = Geology, geography and global energy*, 4, pp. 43–48. (In Russ.)

- Evensen G. (1994). Sequential data assimilation with a non-linear quasi-geostrophic model using Monte Carlo methods to forecast error statistics. *J Geophys Res*, 99(C5), pp. 10143–10162. <https://doi.org/10.1029/94JC00572>
- Gladkov E.A., Gladkova E.E. (2008). Ambiguity of geological and technological information in the process of adaptation of the hydrodynamic model. *Burenie i nefi*, 10, pp. 40–41. (In Russ.)
- Hamam H., Ertekin T.A. (2018). Generalized varying oil compositions and relative permeability screening tool for continuous carbon dioxide injection in naturally fractured reservoirs. *SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition*. <https://doi.org/10.2118/192194-MS>
- Ignatenko A.M., Makarova I.L., Kopyrin A.S. (2019). Methods for preparing data for the analysis of semi-structured time series. *Programmnye sistemy i vychislitel'nye metody*, 4, pp. 87–94. (In Russ.) <https://doi.org/10.7256/2454-0714.2019.4.31797>
- Kaigorodov S.V. (2022). Typical mistakes when creating hydrodynamic models. Part I. Geological model upscaling. *Proneft*, 2, pp. 52–58. (In Russ.)
- Kidner D.B. (2003). Higher-order interpolation of regular grid digital elevation models. *International Journal of Remote Sensing*, 24(14), pp. 2981–2987. <https://doi.org/10.1080/0143116031000086835>
- Kostikov D.V., Petrov A.N., Lyalin V.E. (2007). Preparation of initial data for the problem of interpreting geophysical well surveys using a multilayer neural network. *Proc. Int. Symp. Reliability and Quality*, v. 1, pp. 123–128. (In Russ.)
- Li S., Chen J., Xiang J. (2020). Applications of deep convolutional neural networks in prospecting prediction based on two-dimensional geological big data. *Neural computing and applications*, 32(7), pp. 2037–2053. <https://doi.org/10.1007/s00521-019-04341-3>
- Liu B., Li Y., Li G., & Liu A. (2019). A spectral feature based convolutional neural network for classification of sea surface oil spill. *ISPRS International Journal of Geo-Information*, 8(4), p. 160. <https://doi.org/10.3390/ijgi8040160>
- Lydia A., Francis S. (2019). Adagrad – an optimizer for stochastic gradient descent. *Int. J. Inf. Comput. Sci.*, 6(5), pp. 566–568.
- Minmin Cai, Núria Jiménez, Martin Krüger, Huan Guo, Yao Jun, Nontje Straaten, Hans H. Richnow (2015). Potential for aerobic and methanogenic oil biodegradation in a water flooded oil field (Dagang oil field). *Fuel*, 141, pp. 143–153. <https://doi.org/10.1016/j.fuel.2014.10.035>
- Muslimov R.Kh. (2012). Oil recovery: past, present, future. Kazan: Fen, 663 p. (In Russ.)
- Novikova S., Rizvanova Z., Ziniukov R., Usmanov S. (2020). Prospects of geochemical monitoring on the basis of borehole oil samples at bypassed oil reserves localization. *Int. Multidis. Sci. GeoConf. SGEM*, pp. 739–744. <https://doi.org/10.5593/sgem2020/1.2/s06.094>
- Nurgaliev D., Ziniukov R., Sudakov V., Fakhriev, N., Averyanov A. (2021). Evaluation of the applicability of biodegradationMarkers for identification of the bypassed oil zones. *21st Int. Multidis. Sci. GeoConf. SGEM*, pp. 935–941. <https://doi.org/10.5593/sgem2021/1.1/s06.113>
- Nurgaliev et al. (2006). Variation of i-butane/n-butane ratio in oils of the Romashkino oil field for the period of 1982–2000: Probable influence of the global seismicity on the fluid migration. *Journal of Geochemical Exploration*, 89(1–3), pp. 293–296. <https://doi.org/10.1016/j.gexplo.2005.12.022>
- O'Shea K., Nash R. (2015). An introduction to convolutional neural networks. arXiv preprint arXiv:1511.08458.
- Ribeiro M.I. (2004). Kalman and extended kalman filters: Concept, derivation and properties. Institute for Systems and Robotics, 46 p.
- Rifai A.P., Aoyama H., Tho N.H., Dawal S.Z.M., Masruroh N.A. (2020). Evaluation of turned and milled surfaces roughness using convolutional neural network. *Measurement*, 161, 107860. <https://doi.org/10.1016/j.measurement.2020.107860>
- Rukundo O. (2021). Evaluation of Rounding Functions in Nearest Neighbor Interpolation. *International Journal of Computational Methods*, 18(08), 2150024. <https://doi.org/10.1142/S0219876221500249>
- Ryzhov A.E. et al. (2013). Physical and mathematical modeling of multiphase filtration in the design of the development of the oil rim of the Yen-Yakhinskoye oil and gas condensate field. *Vesti gazovoi nauki*, 1(12), pp. 126–137. (In Russ.)
- Semyachkov A.I. (2009). Filtration heterogeneity of fractured rocks. Moscow: Gornaya kniga, 151 p. (In Russ.)
- Starovoitov V.V., Golub Yu.I. (2021). Data normalization in machine learning. *Informatics*, 18(3), pp. 83–96. (In Russ.) <https://doi.org/10.37661/1816-0301-2021-18-3-83-96>
- Stepanov S.V., Sokolov S.V., Ruchkin A.A., Stepanov A.V., Knyazev A.V., Korytov A.V. (2018). The problems of assessing the mutual influence of production and injection wells based on mathematical modeling. *Vestnik Tyumenskogo gosudarstvennogo universiteta. Fiziko-matematicheskoe modelirovanie. Neft, gaz, energetika*, 4(3), pp. 146–164. (In Russ.) <https://doi.org/10.21684/2411-7978-2018-4-3-146-164>

Ta, J., Li S., Chen J., Liu C., Wang Y. (2021). Mineral prospectivity prediction via convolutional neural networks based on geological big data. *Journal of Earth Science*, 32(2), pp. 327–347. <https://doi.org/10.1007/s12583-020-1365-z>

Tan J., NourEldeen N., Mao K., Shi J., Li Z., Xu T., Yuan Z. (2019). Deep learning convolutional neural network for the retrieval of land surface temperature from AMSR2 data in China. *Sensors*, 19(13), 2987. <https://doi.org/10.3390/s19132987>

Toro-Vizcarrondo C., Wallace T.D. (1968). A test of the mean square error criterion for restrictions in linear regression. *Journal of the American Statistical Association*, 63(322), pp. 558–572. <https://doi.org/10.1080/01621459.1968.11009275>

Wen Xian-Huan, and Wen H. Chen (2006). Real-time reservoir model updating using ensemble Kalman filter with confirming option. *SPE J.*, 11(04), pp. 431–442. <https://doi.org/10.2118/92991-PA>

Zaikin A., Salimov R. (2019). An application of Kalman filter model to reservoir pressure maintenance. *Int. Multidis. Sci. GeoConf. SGEM*, (1.2), pp. 627–634. <https://doi.org/10.5593/sgem2019/1.2/S06.079>

Zaitsev M.V., Mikhailov N.N., Tumanova E.S. (2021). Non-linear filtration models and the effect of nonlinearity parameters on flow rates in low-permeability reservoirs. *Georesury = Georesources*, 23(4), pp. 44–50. <https://doi.org/10.18599/grs.2021.4.5>

Zakrevskii K.E. (2009). Geological 3D modeling. Moscow: Maska, 376 p. (In Russ.)

Zhou, Zhuang, Shengyang Li, and Yuyang Shao (2018). Crops classification from sentinel-2A multi-spectral remote sensing images based on convolutional neural networks. *IGARSS 2018-2018 IEEE Int. Geoscience and Remote Sensing Symposium*. <https://doi.org/10.1109/IGARSS.2018.8518860>

Zinoviev A.M. et al. (2013). Investigation of rheological properties and filtration features of high-viscosity oils from the fields of the Samara region. *Vestnik Samarskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya: Tekhnicheskie nauki*, 2, pp. 197–205. (In Russ.)

About the Authors

Vladislav A. Sudakov – Deputy Director of the Institute for Innovations, Director of Hard-to-Recover Reserves Simulation Research and Educational Center, Institute of Geology and Petroleum Technology, Kazan Federal University
Bolshaya Krasnaya str., 4, Kazan, 420111, Russian Federation

Rinat I. Safuanov – Researcher, Hard-to-Recover Reserves Simulation Research and Educational Center, Institute of Geology and Petroleum Technology, Kazan Federal University
Bolshaya Krasnaya str., 4, Kazan, 420111, Russian Federation

Aleksey N. Kozlov – Junior Researcher, Hard-to-Recover Reserves Simulation Research and Educational Center, Institute of Geology and Petroleum Technology, Kazan Federal University

Bolshaya Krasnaya str., 4, Kazan, 420111, Russian Federation
e-mail: ankozlov.oil@gmail.com

Timur M. Porivaev – Engineer, Hard-to-Recover Reserves Simulation Research and Educational Center, Institute of Geology and Petroleum Technology, Kazan Federal University
Bolshaya Krasnaya str., 4, Kazan, 420111, Russian Federation

Artem A. Zaikin – Researcher, Hard-to-Recover Reserves Simulation Research and Educational Center, Institute of Geology and Petroleum Technology, Kazan Federal University
Bolshaya Krasnaya str., 4, Kazan, 420111, Russian Federation

Rustam A. Zinykov – Junior Researcher, Hard-to-Recover Reserves Simulation Research and Educational Center, Institute of Geology and Petroleum Technology, Kazan Federal University

Bolshaya Krasnaya str., 4, Kazan, 420111, Russian Federation

Azat A. Lutfullin – Cand. Sci. (Engineering), Deputy Head of the Department of Field Development, Tatneft-Dobycha, Tatneft PJSC

Lenin str., 75, Almetyevsk, 423450, Russian Federation

Ildar Z. Farhutdinov – Head of Oil and Gas Fields Development Department, Tatneft PJSC

Telman str., 88, Almetyevsk, 423462, Russian Federation

Ilgiz Z. Tylyakov – Leading Specialist, Oil and Gas Fields Development Department, Tatneft PJSC

Telman str., 88, Almetyevsk, 423462, Russian Federation

Manuscript received 20 September 2022;

Accepted 9 November 2022; Published 20 December 2022