

УДК 622.276

Статья / Article

© ПНИПУ / PNRPU, 2025

Применение алгоритмов машинного обучения для совершенствования моделирования карбонатного рифового резервуара**С.Н. Кривошеков, А.А. Кочнев, И.С. Путилов, Д.О. Ширинкин, А.Н. Боталов, Е.С. Ожгибесов, П.О. Чалова**

Пермский национальный исследовательский политехнический университет (Российская Федерация, 614990, г. Пермь, Комсомольский пр., 29)

Application of Machine Learning Algorithms for Enhanced Modeling of a Carbonate Reef Reservoir**Sergey N. Krivoschekov, Alexander A. Kochnev, Ivan S. Putilov, Dmitriy O. Shirinkin, Andrey N. Botalov, Evgeny S. Ozhgibesov, Polina O. Chalova**

Perm National Research Polytechnic University (29 Komsomolskiy av., Perm, 614990, Russian Federation)

Получена / Received: 30.09.2024. Принята / Accepted: 05.12.2024. Опубликовано / Published: 24.02.2025

Ключевые слова:

карбонатный резервуар, система заводнения, высокопроницаемые интервалы, машинное обучение, случайный лес, градиентный бустинг, метод опорных векторов, анализ чувствительности.

Разработка и моделирование карбонатных резервуаров сложного строения является актуальной задачей. В условиях высокой неоднородности свойств коллектора, обусловленной особенностями формирования, частой сменой циклов осадконакопления и наличием диагенетических преобразований, возникает высокая степень неопределенности в процессе моделирования и, как следствие, прогноза показателей разработки. Недоучет влияния диагенетических процессов на изменение фильтрационно-емкостных свойств может оказать критическое влияние на организацию и управление системой заводнения. При изучении геологического строения месторождения Альфа выявлены интервалы высокопроницаемых коллекторов (до 18 Дарси). В рамках данного исследования предложен подход выделения подобных интервалов с целью уточнения динамической модели месторождения на основе методов машинного обучения. В работе проведено сравнение следующих алгоритмов: градиентный бустинг, случайный лес и метод опорных векторов. По результатам исследования выявлены оптимальные алгоритмы, позволяющие с высокой степенью точности прогнозировать интервалы высокой проницаемости. Для улучшения адаптации модели по истории разработки месторождения предлагается использовать модель, обученную по данным ядра и геофизических исследований скважин. Для учета рисков, связанных с высокопроницаемыми интервалами, при бурении новых скважин рекомендуется использовать модель, обученную только по геофизическим исследованиям скважин. В работе выполнен анализ чувствительности при задании свойств для высокопроницаемых интервалов – абсолютная проницаемость и относительные фазовые проницаемости. Выполнено обновление куба проницаемости динамической модели, адаптация модели и расчеты по оптимизации системы заводнения. На основе прогнозного анализа на модели с высокопроницаемыми интервалами предложен ряд мер по оптимизации системы разработки для снижения рисков прорыва воды в высокопроницаемых интервалах. По результатам прогнозных расчетов эти меры позволят дополнительно получить 750 тыс. м³ нефти.

Keywords:

carbonate reservoir, waterflood system, high-permeability intervals, machine learning, random forest, gradient boosting, support vector method, sensitivity analysis.

The development and modeling of carbonate reservoirs with complex structure is an actual task. In conditions of high heterogeneity of reservoir properties due to the peculiarities of formation, frequent change of sedimentation cycles and the presence of diagenetic transformations, there is a high degree of uncertainty in the modeling process and, as a consequence, in the forecast of development indicators. Underestimation of the influence of diagenetic processes on changes in filtration-capacity properties can have a critical impact on the organization and management of the waterflood system. When studying the geological structure of the Alpha field, intervals of highly permeable reservoirs (up to 18 Darcies) were identified. This study proposes an approach to identify such intervals in order to refine the dynamic model of the field based on machine learning methods. The paper compares the following algorithms: gradient boosting, random forest and support vector method. Based on the results of the study, the optimal algorithms were identified that allow predicting high permeability intervals with a high degree of accuracy. To improve model adaptation to the field development history, it is suggested to use a model trained on core and geophysical well survey data. To take into account the risks associated with highly permeable intervals, when drilling new wells, it is recommended to use a model trained only on geophysical well tests. In this paper, sensitivity analysis was performed when specifying properties for highly permeable intervals - absolute permeability and relative phase permeabilities. The permeability cube of the dynamic model was updated, the model was adapted and calculations on waterflood system optimization were performed. Based on the predictive analysis on the model with highly permeable intervals, a number of measures were proposed to optimize the development system to reduce the risk of water breakthrough in highly permeable intervals. According to the results of the forecast calculations, these measures will provide additional 750 thousand m³ of oil.

© **Кривошеков Сергей Николаевич** – кандидат технических наук, ведущий научный сотрудник кафедры геологии нефти и газа (тел.: +007 (342) 219 83 07, e-mail: krivoschekov@gmail.com). Контактное лицо для переписки.

© **Кочнев Александр Александрович** – кандидат технических наук, доцент кафедры геологии нефти и газа (тел.: +007 (342) 219 83 07, e-mail: sashakoch93@gmail.com).

© **Путилов Иван Сергеевич** – доктор технических наук, доцент, профессор кафедры нефтегазового инжиниринга (тел.: +007 (342) 219 83 07, e-mail: ivan.putilov@pnn.lukoil.com).

© **Ширинкин Дмитрий Олегович** – младший научный сотрудник кафедры геологии нефти и газа (тел.: +007 (342) 219 83 07, e-mail: shirinkindo.40@mail.ru).

© **Боталов Андрей Николаевич** – младший научный сотрудник кафедры геологии нефти и газа (тел.: +007 (342) 219 83 67, e-mail: botalov97@yandex.ru).

© **Ожгибесов Евгений Сергеевич** – младший научный сотрудник кафедры геологии нефти и газа (тел.: +007 (342) 219 83 67, e-mail: ozhgibesov2015@yandex.ru).

© **Чалова Полина Олеговна** – младший научный сотрудник кафедры геологии нефти и газа (тел.: +007 (342) 219 83 67, e-mail: chalovapolina@yandex.ru).

© **Sergey N. Krivoschekov** (Author ID in Scopus: 54410873700, ORCID: 0000-0002-9748-6291) – PhD in Engineering, Leading Researcher at the Department of Oil and Gas Geology (tel.: +007 (342) 219 83 07, e-mail: krivoschekov@gmail.com). The contact person for correspondence.

© **Alexander A. Kochnev** (Author ID in Scopus: 55747336200) – PhD in Engineering, Associate Professor at the Department of Oil and Gas Geology (tel.: +007 (342) 219 83 07, e-mail: sashakoch93@gmail.com).

© **Ivan S. Putilov** (Author ID in Scopus: 25723777700) – Doctor of Engineering, Associate Professor, Professor of the Department of Petroleum Engineering (tel.: +007 (342) 219 83 07, e-mail: ivan.putilov@pnn.lukoil.com).

© **Dmitriy O. Shirinkin** – Junior Researcher at the Department of Oil and Gas Geology (tel.: +007 (342) 219 83 07, e-mail: shirinkindo.40@mail.ru).

© **Andrey N. Botalov** (Author ID in Scopus: 58173917100, ORCID: 0000-0003-4291-7362) – Junior Researcher at the Department of Oil and Gas Geology (tel.: +007 (342) 219 83 67, e-mail: botalov97@yandex.ru).

© **Evgeny S. Ozhgibesov** (Author ID in Scopus: 57486568400, ORCID: 0009-0004-8235-0836) – Junior Researcher at the Department of Oil and Gas Geology (tel.: +007 (342) 219 83 67, e-mail: ozhgibesov2015@yandex.ru).

© **Polina O. Chalova** (Author ID in Scopus: 57223986143, ORCID: 0000-0002-4862-0116) – Junior Researcher at the Department of Oil and Gas Geology (tel.: +007 (342) 219 83 67, e-mail: chalovapolina@yandex.ru).

Просьба ссылаться на эту статью в русскоязычных источниках следующим образом:

Применение алгоритмов машинного обучения для совершенствования моделирования карбонатного рифового резервуара / С.Н. Кривошеков, А.А. Кочнев, И.С. Путилов, Д.О. Ширинкин, А.Н. Боталов, Е.С. Ожгибесов, П.О. Чалова // Недропользование. – 2025. – Т.25, №1. – С. 9-20. DOI: 10.15593/2712-8008/2025.1.2

Please cite this article in English as:

Krivoschekov S.N., Kochnev A.A., Putilov I.S., Shirinkin D.O., Botalov A.N., Ozhgibesov E.S., Chalova P.O. Application of machine learning algorithms for enhanced modeling of a carbonate reef reservoir. *Perm Journal of Petroleum and Mining Engineering*, 2025, vol.25, no.1, pp. 9-20. DOI: 10.15593/2712-8008/2025.1.2

Введение

Карбонатные рифовые резервуары характеризуются сложным геологическим строением: наличием каверн, трещин, широким распространением вторичных изменений. Литолого-фациальная неоднородность в подобных резервуарах обусловлена особенностями формирования, частой сменой циклов осадконакопления и наличием диагенетических преобразований. Наиболее часто встречаются следующие вторичные преобразования: образование трещин, выщелачивание, доломитизация, перекристаллизация. Данные процессы являются определяющими при формировании емкостных и фильтрационных свойств [1, 2].

Процессы происходят с различной степенью интенсивности и могут оказывать значительное влияние на процесс разработки месторождения. Цементация, доломитизация и выщелачивание оказывают прямое влияние на изменение пористости и проницаемости [3, 4]. Образование вторичных каверн и трещин способствует значительному улучшению свойств резервуара, а также увеличению продуктивности скважин, но, с другой стороны, эти процессы во многих случаях являются причинами преждевременных прорывов воды [5–8]. Недоучет данных процессов, а в особенности выщелачивания, может иметь критическое значение при организации процесса заводнения и управления обводненностью [9–11]. Влияние выщелачивания и трещиноватости на эффективность заводнения описано в работе [12]. Также важной задачей является учет диагенетических изменений при создании статических и динамических моделей месторождения и оценке запасов месторождения [13]. В работе предложена методика построения куба проницаемости с учетом кавернозности на основе расчета вторичной пористости по данным плотностного и нейтронного каротажей и геостатистического моделирования. Методика позволила успешно провести воспроизведение истории разработки месторождения на модели. В работе [14] описан подход на основании интеграции разномасштабных данных (сейсмика, керн, модель трещин), на основе данного подхода предложен автоматический алгоритм, позволяющий создавать модель сложнопостроенных карбонатных коллекторов. В работе [15] выполнено изучение и моделирование высокопроницаемых интервалов. Выделение высокопроницаемых интервалов основано на керновых данных (проницаемость > 350 мД) и промыслово-геофизических исследований. Результаты моделирования позволили выполнить воспроизведение истории разработки с учетом влияния заводнения. Авторы [16] указывают на актуальность выделения и моделирования высокопроницаемых интервалов. Связанность высокопроницаемых тел является одним из важнейших параметров, определить который можно, используя интегрированный подход, учитывающий данные изучения керна, шлифов, ГИС и данные по разработке. Хорошая корреляция отмечается между электрическими методами каротажа и высокопроницаемыми интервалами.

В работе [17] подчеркивается, что моделирование проницаемости в карбонатных коллекторах сложного строения является сложной задачей. Предложен подход на основе методов машинного обучения (кластеризация) для прогноза высокопроницаемых зон.

Технологии машинного обучения активно внедряются в нефтегазовую отрасль для решения множества различных задач. Технологии позволяют автоматизировать рутинные процессы, снизить

субъективность человеческого фактора и осуществлять поиск невидимых связей между параметрами. Сегодня технологии внедряются на всех стадиях жизни проекта – от геологоразведки и разработки до сбора и транспортировки продукции [18–21].

Машинное обучение широко используется для прогноза свойств резервуара путем комплексирования геофизических исследований скважин и результатов сейсморазведки [22, 23]. Прогноз свойств и петротипов резервуара является одной из важнейших задач [24, 25].

В работе [26] описывается возможность применения алгоритмов для оценки характера насыщения пластов. Алгоритм градиентного бустинга успешно использован для выделения фаций на основе кривых ГИС [27]. Ряд работ описывает возможность использования машинного обучения для литологического расчленения разреза по результатам ГИС [28, 29] и корреляции разрезов скважин [30].

Множество работ направлены на разработку методологий типизации карбонатных резервуаров с использованием методов машинного обучения [31, 32].

Ряд работ направлен на прогноз проницаемости, в том числе и карбонатных коллекторов [33]. Отмечается важность достоверного прогноза проницаемости в условиях высокой неоднородности резервуара. В работе [34] предложено использование алгоритма кластеризации на основе графов с несколькими вариантами для прогноза проницаемости на основе данных ГИС.

В данной работе будет выполнен сравнительный анализ алгоритмов классификации для прогноза высокопроницаемых интервалов. По результатам классификации по скважинам будут выделены интервалы с аномально высокой проницаемостью. Затем выполнена интерполяция по объему куба.

Для полученных интервалов будет выполнено многовариантное моделирование с целью оценки чувствительности параметров на качество адаптации модели. По результатам моделирования будет выполнен прогноз технологических показателей и предложены решения по оптимизации закачки с учетом высокопроницаемых интервалов.

Геология

Объектом исследования является месторождение Альфа, располагающееся в пределах Тимано-Печорской провинции.

Нефтеносность месторождения Альфа связана с нижефаменскими рифовыми массивами, которые образовывались последовательно друг на друге в ходе одного задонского сиквенса и трех елецких сиквенсов рифостроения. Нефтедержащими коллекторами являются как карбонатные отложения собственно рифовой фации, так и отложения зарифового шельфа.

Литологическое описание продуктивного интервала проведено по керну, полученного в результате бурения двенадцати скважин. Отложения рифовой постройки представлены известняками и среднезернистым вторичным доломитом с реликтами детритово-водорослевых известняков, вторично стустковато-комковатых, биогермных. Отложения зарифового шельфа сложены известняками микробиально-детритовыми серого, темно-серого, светло-красноватого цвета, мелко-скрытокристаллическими, доломитизированным, с включением аргиллитов (до 15 %).

Свойства резервуара представлены в табл. 1.

Таблица 1

Свойства резервуара

Пласт	Параметр	Ср. знач.	Медиана	Мин.	Макс.
D ₃ fm ₁ (el1)	k, мД	86,05	7,55	0,1	9058,2
	φ, %	7,5	6,95	0,4	21,2
D ₃ fm ₁ (el3)	k, мД	128	2,75	0,1	18143
	φ, %	6,45	6,15	0,9	29,6

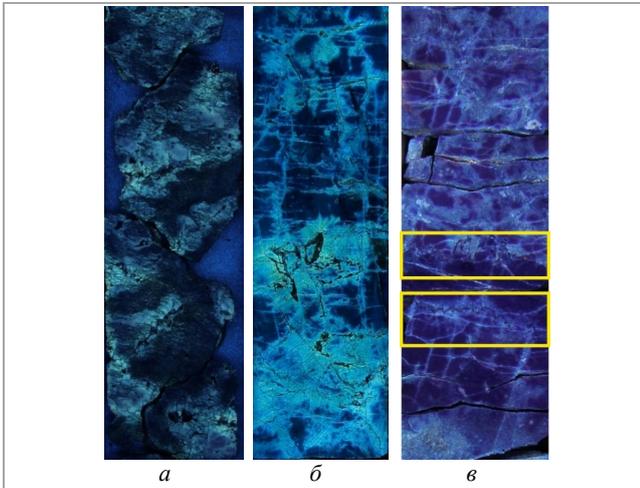


Рис. 1. Виды кавернозных пустот месторождения Альфа: а – каверны; б – закарстованные трещины; в – закарстованные стилолитовые швы (желтым)

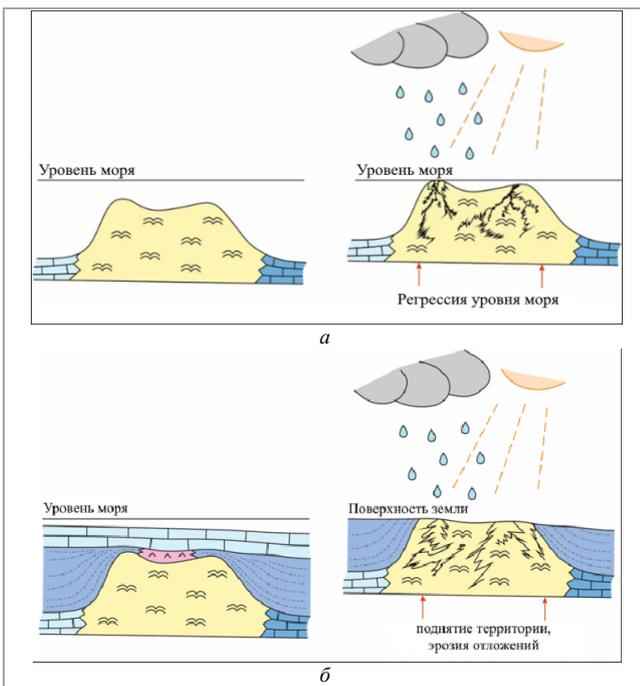


Рис. 2. Механизмы формирования карстовых процессов: а – в ходе регрессии уровня моря; б – в ходе эрозии вышележащих отложений

Карбонатный резервуар характеризуется сложным типом пустотного пространства, представляющего собой совокупность межзерновых, кавернозных и трещиноватых пустот. На формирование пустотного пространства оказывают высокую степень влияния различные вторичные изменения пород. Высокая степень вторичных преобразований известняков способна приводить к образованию высокопродуктивных прослоев с аномальными свойствами, именующимися высокопроницаемыми интервалами – суперколлекторами.

Процесс выщелачивания в карбонатных породах является одним из доминирующих факторов преобразования пустотного пространства. В ходе изучения кернового материала было установлено, что рифогенные породы нижнефаменского возраста месторождения Альфа имеют сложное строение пустотного пространства как в латеральном, так и в вертикальном направлениях. Сложность обусловлена значительным распространением в породах каверн, закарстованных трещин и стилолитовых швов (рис. 1), а также замещением рифогенных известняков вторичными доломитами.

Ключевую роль при формировании карстовых пустот и вторичных доломитов могли сыграть процессы растворения и замещения в поверхностных или приповерхностных условиях.

В связи с этим предложены две теории формирования карстовых пустот. Первая теория предполагает, что микробийные известняки накапливались на мелководном шельфе и многократно обнажались в разные интервалы фаменского времени в результате понижения уровня моря. В керне рифогенных задонско-елецких отложений обнаружены красные, красно-розовые и красно-коричневые включения, что может указывать на наличие в породах оксидов железа, являющихся индикаторами окислительных условий и аридного климата. Эти соединения в виде коллоидов и растворов могли переноситься пресными водами и накапливаться на теле рифа. Метеорные воды могли сыграть решающую роль в формировании карстовых пустот в рифогенных породах резервуара Альфа (рис. 2).

Согласно второй теории, карстовые пустоты могли образоваться в результате растворения пород атмосферными водами, проникающими в породы через инфильтрацию во время эрозионных процессов, которые могли происходить на более позднем этапе. Это подтверждается наличием несогласия выше по разрезу между отложениями верхнего девона и нижнего карбона, где породы турнейского яруса полностью, а фаменского – частично, размыты, что связано с формированием современной структуры бассейна в условиях тектонического сжатия складчатой системы (см. рис. 2).

Материалы и методы

Исходными данными для исследования являются кривые ГИС по восьми скважинам, результаты исследования керна, шлифов, результаты потокометрических исследований. В работе [35] выполнены анализ и комплексирование разномасштабных исследований. По результатам анализа высокопроницаемые интервалы с вероятностью P90, P50, P10. Результаты выделения высокопроницаемых интервалов использованы в качестве разметки данных для обучения модели в настоящей работе.

Методы исследования заключаются в статистическом анализе данных и использовании алгоритмов машинного обучения для выделения высокопроницаемых интервалов, использовании подходов динамического моделирования резервуара.

Размеченные высокопроницаемые интервалы выбраны в качестве целевой переменной для классификации. Модели были обучены для двух различных наборов данных: результаты исследований керна в сочетании с данными ГИС; только результаты ГИС. Результатами керновых исследований послужили пористость и проницаемость породы. В качестве результатов ГИС использованы кривые, которые имеют наибольшую корреляцию с величиной керновой

проницаемости: кривые коэффициента пористости, определенные по акустическому (КРА), плотностному (КРД) и нейтронному (КРН) методам, а также коэффициент эффективной пористости, определенный по ядерно-магнитному каротажу (СМФФ); кривые коэффициента проницаемости, которые определены при помощи ядерно-магнитного каротажа по модели SDR (KSDR), а также коэффициент проницаемости, рассчитанный по модели Тимура-Коатеса (КТМ); кривая доли содержания нефти в общем объеме пустотного пространства (FOIL); плотность трещин по FMI. В базу включены результаты исследований керна и ГИС по восьми скважинам месторождения Альфа.

В качестве алгоритмов машинного обучения выбраны градиентный бустинг, случайный лес и метод опорных векторов. Использование данных алгоритмов обусловлено их высокой степенью успешного применения в различных областях, в том числе в прогнозе свойств резервуара [36–38].

Для оценки качества моделей строились матрицы ошибок, а также вычислялись стандартные метрики для оценки моделей классификации: Accuracy, Recall, Precision, F1-score, ROC-AUC. Метрики качества моделей классификации используются для оценки эффективности и производительности алгоритмов классификации. Они предоставляют информацию о том, насколько качественно модель способна разделять объекты разных классов [39–43].

Распределение высокопроницаемых интервалов в межскважинном пространстве производилось, основываясь на математических методах геостатистики, которые заложены в инструменты стохастического индикаторного моделирования в программном обеспечении RMS 13.1.1 от компании AspenTech. Модуль для стохастического распределения параметров в объеме именуется Petrophysical Modeling и основывается на вариограммном анализе. В качестве тренда для более корректного распределения использовался суммарный куб вторичных изменений карбонатов, а именно сумма трещиноватости, выщелачивания, доломитизации и перекристаллизации.

На следующем этапе использован подход многовариантного моделирования и статистического анализа для оценки влияния параметров суперколлектора на результаты адаптации гидродинамической модели.

Для получения распределения проницаемости в интервалах суперколлектора применена методика расчета гидравлической единицы потока (FZI) [44]. На образцах керна по формуле (1) с их последующей классификацией по методу DRT [45] по формуле (2) для выделения образцов со схожими фильтрационными характеристиками.

$$FZI = \frac{0,0314 \sqrt{\frac{k}{\phi}}}{1 - \phi}, \quad (1)$$

где k – коэффициент проницаемости, мД; ϕ – коэффициент пористости, доли ед.

$$DRT = 2 \ln(FZI) + 10,6. \quad (2)$$

Далее предложены три варианта категоризации образцов керна по их фильтрационным характеристикам, и наилучший вариант определен при помощи расчета t -критерия Стьюдента, который основан на сравнении средних значений разных выборок (3).

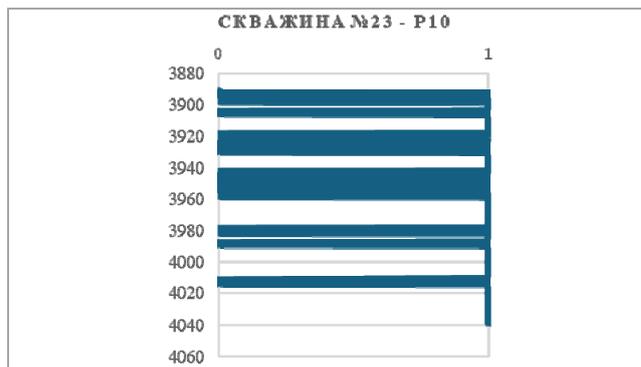


Рис. 3. Интервалы суперколлекторов по скважине № 23. Реализация P10

Таблица 2

Сравнение метрик алгоритмов (обучение на данных керна и ГИС)

Метрика/ алгоритм	Градиентный бустинг	Случайный лес	Метод опорных векторов
Accuracy	0,98	0,97	0,96
Precision	0,99	1	0,97
Recall	0,96	0,91	0,91
F1 Score	0,97	0,95	0,94
ROC AUC	1	1	0,98

Таблица 3

Сравнение метрик алгоритмов (обучение на данных ГИС)

Метрика/ алгоритм	Градиентный бустинг	Случайный лес	Метод опорных векторов
Accuracy	0,97	0,97	0,97
Precision	1	1	0,98
Recall	0,9	0,9	0,91
F1 Score	0,95	0,95	0,95
ROC AUC	0,97	0,97	0,97

$$t = \frac{M_1 - M_2}{\sqrt{m_1^2 + m_2^2}}, \quad (3)$$

где M_1 – средняя арифметическая первой сравниваемой категории; M_2 – средняя арифметическая второй сравниваемой категории; m_1 – средняя ошибка первой средней арифметической; m_2 – средняя ошибка второй средней арифметической.

Затем проведен history matching и прогноз показателей разработки. Проведен анализ полученных результатов и предложены оптимизационные мероприятия.

Результаты

На первом этапе осуществлялся прогноз высокопроницаемых интервалов, выделенных с вероятностью P10 [35]. При таком выделении наилучшим образом удается сохранить баланс в выборке при соотношении суперколлектора и обычного коллектора. На рис. 3 ниже представлен пример по скважине № 23 с выделенными интервалами суперколлектора. Для данной скважины выделено наибольшее количество интервалов суперколлекторов.

Результаты расчетов представлены в табл. 2, 3, метрики оценивались на тестовых выборках.

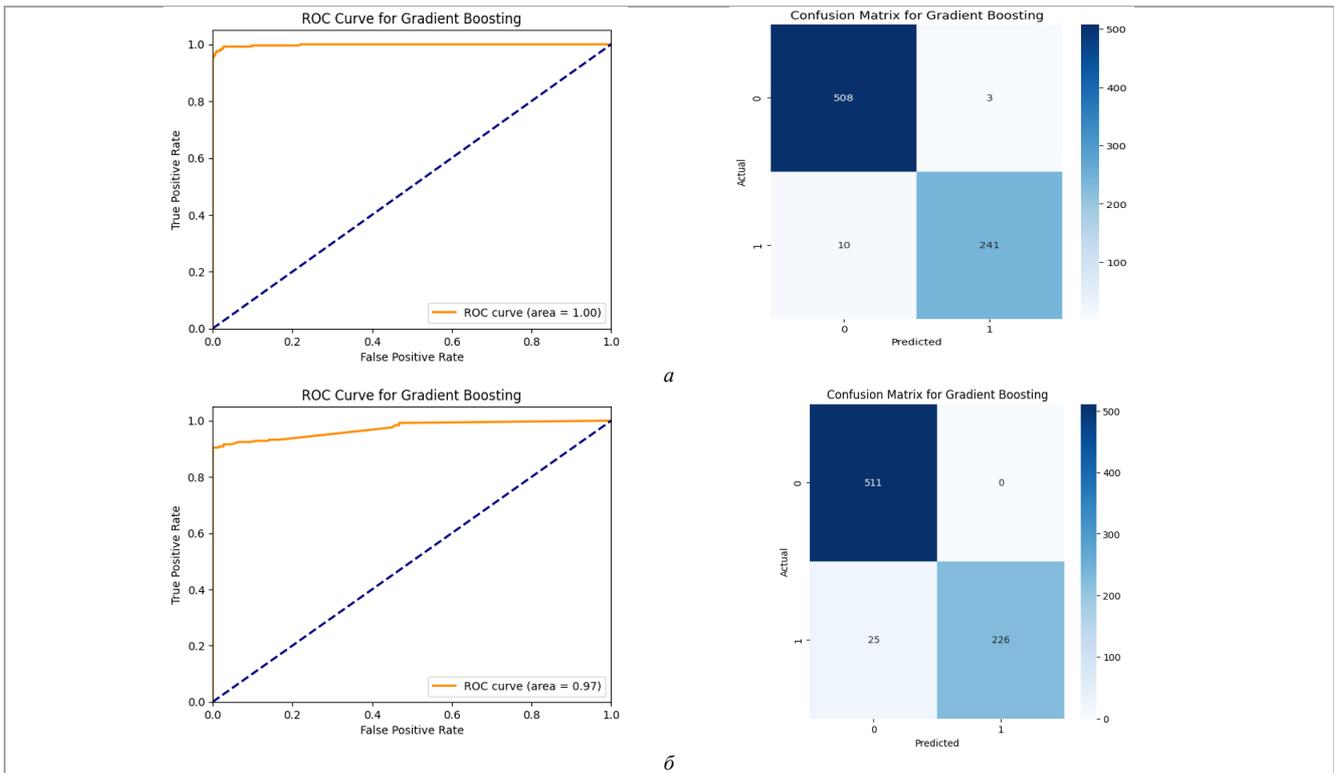


Рис. 4. Кривые ROC-curve и матрицы ошибок для реализации P10: а – обучение на данных керна и ГИС; б – обучение на данных ГИС



Рис. 5. Интервалы суперколлекторов по скважине № 23. Реализация P50

Таблица 4

Сравнение метрик алгоритмов (обучение на данных керна и ГИС)

Метрика/алгоритм	Градиентный бустинг	Случайный лес	Метод опорных векторов
Accuracy	0,99	0,98	0,98
Precision	0,92	0,71	0,5
Recall	0,69	0,31	0,25
F1 Score	0,79	0,43	0,33
ROC AUC	0,98	0,95	0,96

Таблица 5

Сравнение метрик алгоритмов (обучение на данных ГИС)

Метрика/алгоритм	Градиентный бустинг	Случайный лес	Метод опорных векторов
Accuracy	0,99	0,99	0,98
Precision	1	1	0,67
Recall	0,44	0,56	0,38
F1 Score	0,61	0,72	0,48
ROC AUC	0,84	0,85	0,94

Наилучшие значения метрик отмечаются для алгоритма градиентного бустинга. Алгоритм с высокой степенью достоверности позволяет предсказывать наличие интервалов суперколлектора как для набора данных, включающего керн и ГИС, так и отдельно для данных ГИС.

На рис. 4 представлены графики ROC-curve и матрицы ошибок для выбранных оптимальных алгоритмов.

Прогноз интервалов с вероятностью P10 осуществлялся ввиду наиболее сбалансированной выборки и показал высокую достоверность полученной модели.

На следующем этапе выполнялось построение прогнозной модели для выделения суперколлектора с оценкой P50, которая наилучшим образом позволяет отразить фильтрационные процессы в резервуаре [35]. На рис. 5 представлен пример по скважине № 23 с выделенными интервалами суперколлектора.

Результаты расчетов представлены в табл. 4, 5, метрики оценивались на тестовых выборках.

Наилучшие значения метрик отмечаются для алгоритма градиентного бустинга в случае использования комплекса керновых данных и ГИС. Алгоритм с высокой степенью достоверности позволяет предсказывать наличие интервалов суперколлектора. Однако в случае с обучением модели только на данных ГИС метрики Recall и F1 Score значительно снижаются. Для данного случая более эффективным является алгоритм случайного леса.

На рис. 6 представлены графики ROC-curve и матрицы ошибок для выбранных оптимальных алгоритмов.

На рис. 6 отмечается, что прогнозная модель для варианта обучения на данных керна и ГИС применима для классификации, а для варианта обучения только на данных ГИС прогноз суперколлектора недостаточно эффективен. Также для обоих вариантов можно отметить значительное неравенство выборки, что вызывает дисбаланс при обучении и прогнозе в пользу стандартного коллектора.

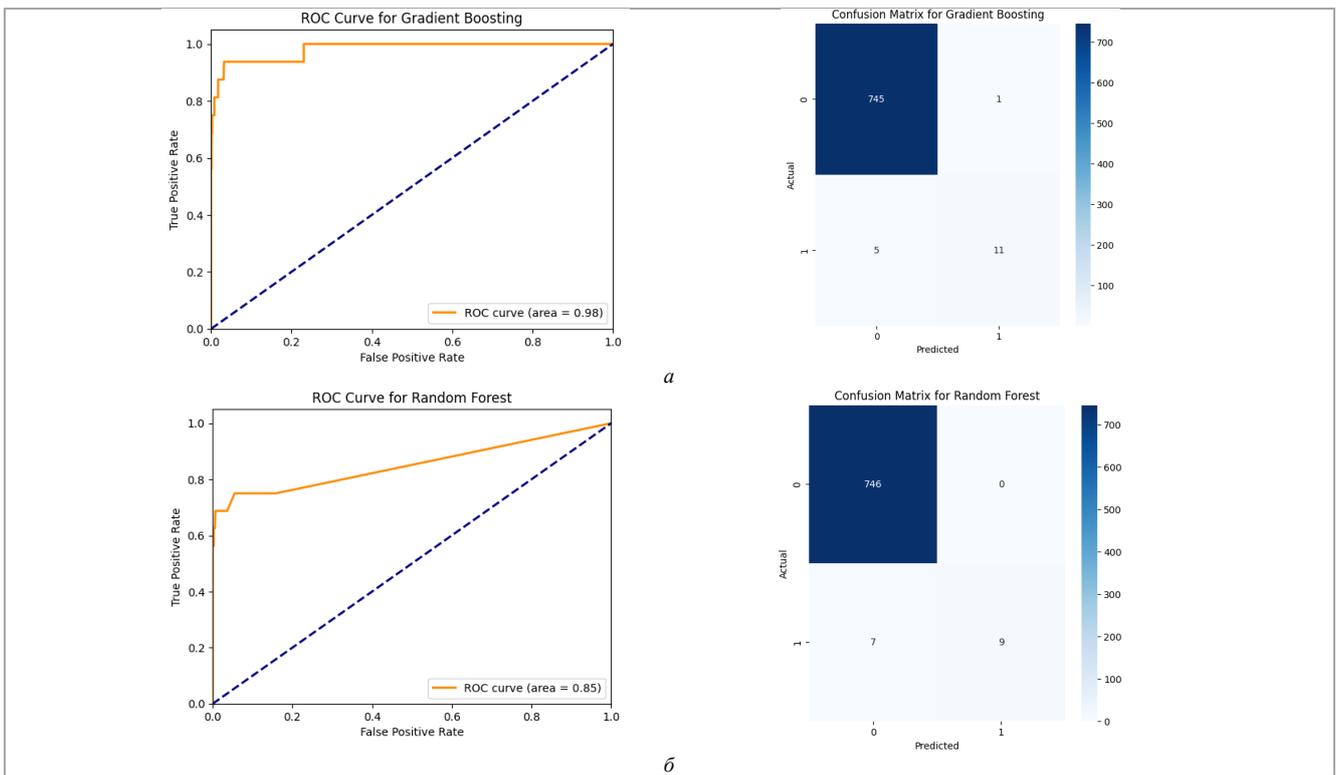


Рис. 6. Кривые ROC-curve и матрицы ошибок для реализации P50: а – обучение на данных керна и ГИС; б – обучение на данных ГИС

Предлагается использование модели, обученной на данных керна и ГИС (вариант P50), для прогноза суперколлектора в рамках решения задачи адаптации модели. Использование модели, обученной на данных ГИС (вариант P10), для учета рисков, связанных с суперколлектором при бурении новых скважин. По результатам исследований ГИС перед проведением перфорации модель позволит предсказывать все возможные интервалы суперколлектора и в случае нагнетательной скважины рассматривать опцию отказа от перфорации высокопроницаемых интервалов.

Далее при помощи стохастических методов распределения геологических параметров в трехмерном пространстве произведена интерполяция интервалов суперколлекторов в межскважинном пространстве. Для наиболее корректного распределения и соответствия геологии резервуара в качестве тренда использован суммарный куб развития вторичных преобразований (рис. 7).

В результате получен трехмерный массив развития суперколлекторов в объеме резервуара, используемый для дальнейших исследований (рис. 8).

На следующем этапе разрабатывались подходы, позволяющие перейти от дискретного куба развития интервалов суперколлекторов к распределению абсолютной проницаемости, которое в дальнейшем будет использоваться для расчетов в гидродинамической модели. Было принято решение: в интервалах стандартного коллектора распределить проницаемость стандартным способом – по петрофизической зависимости проницаемости от пористости, выявленной на всех образцах керна стандартного размера (рис. 9); в высокопроницаемых интервалах (суперколлектор) задать различными способами, после чего просчитать каждый вариант в гидродинамической модели, сравнить сходимость фактических показателей разработки при воспроизведении ее истории и оценить степень влияния изменения результатов расчетов при использовании разных подходов задания проницаемости.

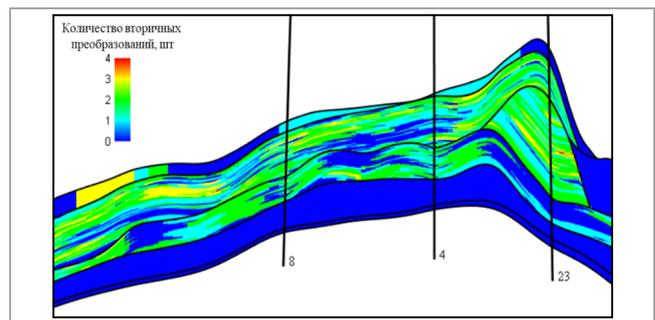


Рис. 7. Разрез суммарного куба развития вторичных преобразований в объеме резервуара

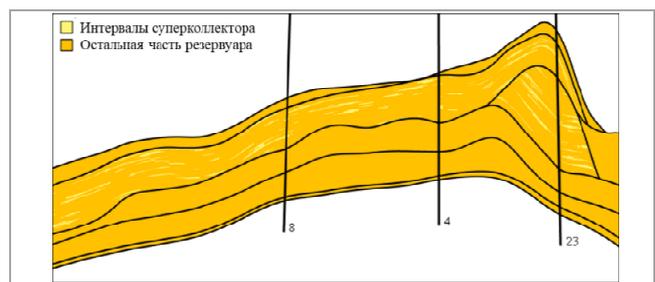


Рис. 8. Разрез итогового куба развития суперколлектора в объеме резервуара, основанного на модели P50

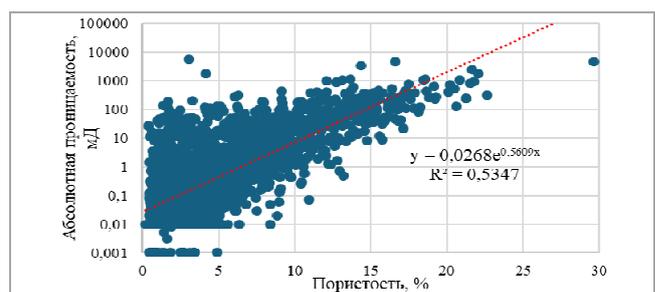


Рис. 9. Стандартная петрофизическая зависимость «проницаемость – пористость» для всех образцов керна стандартного размера

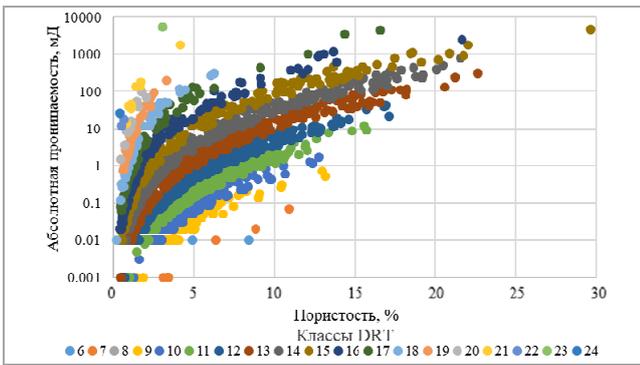


Рис. 10. Классификация образцов керн DRT

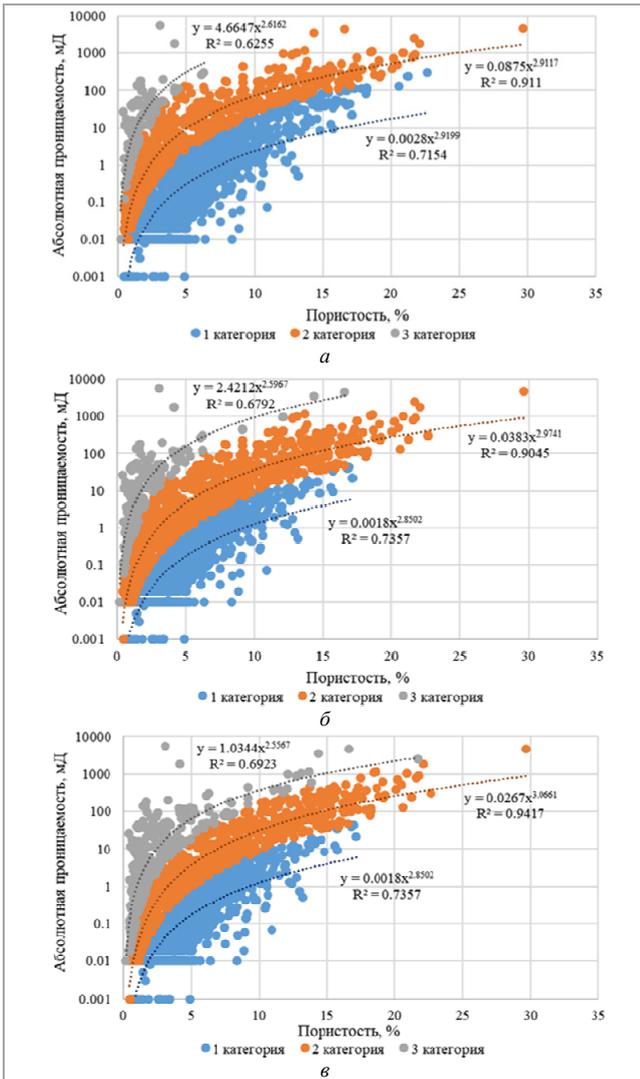


Рис. 11. Варианты выделения новых петрофизических зависимостей: а – 1-й вариант; б – 2-й вариант; в – 3-й вариант

Таблица 6

Сравнение *t*-критерия Стьюдента для проницаемости при разных вариантах классификации образцов керн

Категория	Ср. знач. 1	Ср. знач. 2	<i>t</i> -критерий	<i>p</i> -value
1-й вариант				
1-2-я	3,75	78,06	-8,78	0,000000
2-3-я	78,06	102,16	-0,63	0,526388
2-й вариант				
1-2-я	0,84	49,66	-7,72	0,000000
2-3-я	49,66	126,86	-3,05	0,002346
3-й вариант				
1-2-я	0,84	44,98	-7,48	0,000000
2-3-я	44,98	108,49	-3,12	0,001874

Для задания проницаемости в интервалах суперколлектора выбраны следующие способы:

- одним числом, соответствующим максимальному значению, определенному на стандартных образцах керна;
- одним числом, соответствующим максимальному значению, определенному на полноразмерных образцах керна;
- через уточненные петротипизацией петрофизические зависимости «проницаемость – пористость»;
- через стандартную петрофизическую зависимость «проницаемость – пористость», определенную на всех образцах керн стандартного размера (см. рис. 7).

Для уточнения петрофизической зависимости использован подход петротипизации DRT. Для этого для каждого образца керн рассчитано значение FZI (1). После этого образцы керн по формуле (2) отнесены к различным петротипам согласно классификации DRT (рис. 10).

Далее на основании классов DRT образцы керн объединены разными способами в три масштабных класса для получения петрофизических зависимостей, описывающих достаточный диапазон керновых исследований для использования в гидродинамической модели.

В ходе перебора различных вариаций дифференциации классов DRT на три категории с разным качеством фильтрационно-емкостных свойств принято решение остановиться на трех, которые характеризуются наивысшими коэффициентами детерминации:

- 1-й вариант: 1-я категория – 6–13-й классы DRT; 2-я категория – 14–17-й классы DRT; 3-я категория – 18–24-й классы DRT (рис. 11, а);
- 2-й вариант: 1-я категория – 6–12-й классы DRT; 2-я категория – 13–16-й классы DRT; 3-я категория – 17–24-й классы DRT (рис. 11, б);
- 3-й вариант: 1-я категория – 6–12-й классы DRT; 2-я категория – 13–15-й классы DRT; 3-я категория – 16–24-й классы DRT (рис. 11, в).

Для определения конечного варианта распределения образцов керн по категориям рассчитан *t*-критерий Стьюдента с целью выявления наилучшей классификации с точки зрения дифференциации пористости и проницаемости (табл. 6, 7).

В результате сравнения *t*-критериев Стьюдента принято решение при дальнейших исследованиях использовать 3-й вариант распределения образцов керн по категориям с соответствующими для них петрофизическими зависимостями «проницаемость – пористость».

На следующем этапе рассчитаны итоговые кубы проницаемости для каждого из методов задания проницаемости в интервалах суперколлектора. Средние значения для суперколлектора приведены в табл. 8.

Далее полученные распределения проницаемости загружены в гидродинамическую модель и проведено воспроизведение истории разработки объекта для сравнения сходимости расчетных и фактических показателей эксплуатации. Для более корректного определения потенциала пласта при разных вариантах проницаемости расчеты проводились с ограничением скважин по фактическому забойному давлению. Результаты расчетов представлены после одной итерации (рис. 12, 13, табл. 9).

На рис. 12, 13 можно заметить, что при воспроизведении истории разработки наилучшей сходимостью с историческим трендом характеризуется метод задания проницаемости в суперколлекторе через петрофизическую зависимость для третьей категории, поэтому для дальнейших расчетов будет использована именно эта реализация распределения абсолютной проницаемости.

Таблица 7

Сравнение *t*-критерия Стьюдента для пористости при разных вариантах классификации образцов кернa

Категория	Ср. знач. 1	Ср. знач. 2	<i>t</i> -критерий	<i>p</i> -value
1-й вариант				
1–2-я	4,90	5,24	-1,83	0,067618
2–3-я	5,24	1,60	7,17	0,000000
2-й вариант				
1–2-я	4,67	5,51	-4,65	0,000003
2–3-я	5,51	2,06	8,57	0,000000
3-й вариант				
1–2-я	4,67	5,78	-5,95	0,000000
2–3-я	5,78	2,70	9,58	0,000000

Таблица 8

Средние значения для суперколлектора

Метод задания проницаемости	Среднее значение для суперколлектора, мД	Среднее значение для всей модели, мД
Максимальное значение для стандартных образцов кернa	5574	296,2
Максимальное значение для полноразмерных образцов кернa	11 544	598,2
Петрофизическая зависимость для 1-й категории	1,4	14,2
Петрофизическая зависимость для 2-й категории	40,1	15,1
Петрофизическая зависимость для 3-й категории	970,9	37,6
Стандартная петрофизическая зависимость	35,6	14,8

Следует отметить высокую степень влияния различных способов задания проницаемости в суперколлекторе на динамику добычи нефти и жидкости. Так, разница между максимальной и минимальной накопленной добычей жидкости составила 19 690,7 тыс. м³, что равняется 91,5 % от фактической добычи. Разница между максимальной и минимальной добычей нефти составила 15 060,5 тыс. м³, что равняется 76,2 % от фактической добычи. Обводненность на конец 2023 г. колеблется в диапазоне от 10 до 46 % при фактической обводненности в 11 %.

В предыдущих расчетах использовались средние тренды относительных фазовых проницаемостей (ОФП) для всего облака кернa (рис. 14). На следующем этапе оценивается степень влияния формы кривой ОФП на результаты расчета гидродинамической модели, и для сравнения используются максимальные и минимальные тренды.

Результаты сравнения степени влияния формы кривых ОФП в гидродинамической модели при воспроизведении истории разработки приведены на рис. 15–17 и в табл. 10.

На рис. 15–17 заметно, что форма кривых ОФП оказывает меньшую степень влияния на результаты расчета, нежели абсолютная проницаемость. Так, диапазон изменения накопленной добычи жидкости составил 4,3 % относительно среднего тренда, диапазон изменения накопленной добычи нефти составил 2,9 %, обводненность изменяется в пределах от 15 до 19 %. Стоит отметить, что при использовании в интервалах суперколлектора ОФП с максимальным трендом удалось снизить отклонение накопленной добычи жидкости с 2,5 до 0,5 %, накопленной добычи нефти – с 0,8 до 0,5 %, поэтому для проведения прогнозных расчетов будет использована именно эта форма кривой ОФП. Также преимуществом использования кривой ОФП с максимальным трендом является возможность более консервативно оценить риски преждевременных прорывов воды.

Ввиду наличия высокопроницаемых интервалов, за счет сильного взаимовлияния между добывающими и нагнетательными скважинами, по результатам прогнозных расчетов отмечается прорывной характер обводнения, что указывает на необходимость планирования дополнительных геолого-технических мероприятий (ГТМ) по регулированию обводнения скважин данного месторождения. Модель, созданная стандартным способом, не позволяет отразить данные эффекты.

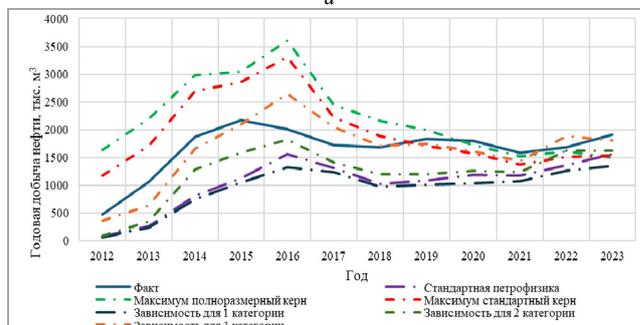
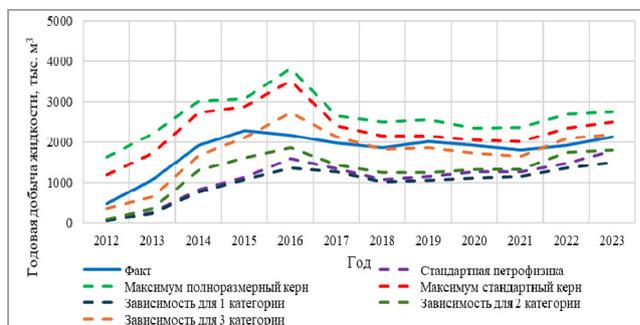


Рис. 12. Сравнение динамики добычи жидкости (а) и нефти (б) при разных вариантах распределения проницаемости в суперколлекторе при воспроизведении истории разработки в гидродинамической модели

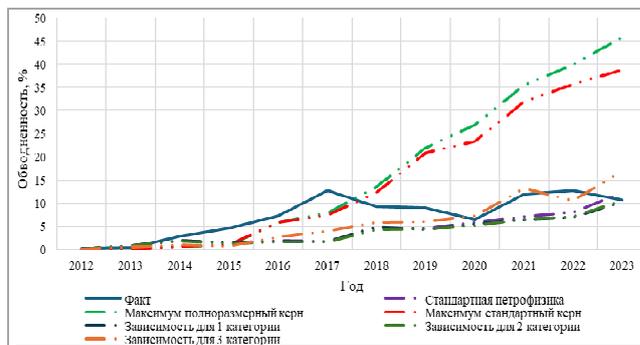


Рис. 13. Сравнение динамики изменения обводненности при разных вариантах распределения проницаемости в суперколлекторе при воспроизведении истории разработки в гидродинамической модели

Таблица 9

Сравнение накопленных показателей при разных вариантах распределения проницаемости в суперколлекторе при воспроизведении истории разработки в гидродинамической модели

Метод задания проницаемости	Накопленная добыча жидкости, тыс. м ³	Накопленная добыча нефти, тыс. м ³	Отклонение накопленной добычи жидкости от факта, %	Отклонение накопленной добычи нефти от факта, %
Максимальное значение для стандартных образцов керна	31 586,6	26 401,9	-46,8	-33,5
Максимальное значение для полноразмерных образцов керна	27 612,5	23 533,0	-28,3	-19,0
Петрофизическая зависимость для 1-й категории	11 895,8	11 341,5	44,7	42,6
Петрофизическая зависимость для 2-й категории	15 318,8	14 633,0	28,8	26,0
Петрофизическая зависимость для 3-й категории	20 974,3	19 622,4	2,5	0,8
Стандартная петрофизическая зависимость	13 184,7	12 491,6	38,7	36,8
Факт	21 516,3	19 773,1		

Таблица 10

Сравнение накопленных показателей при разных ОФП в суперколлекторе при воспроизведении истории разработки в гидродинамической модели

Метод задания проницаемости	Накопленная добыча жидкости, тыс. м ³	Накопленная добыча нефти, тыс. м ³	Отклонение накопленной добычи жидкости от факта, %	Отклонение накопленной добычи нефти от факта, %
Петрофизическая зависимость для 3-й категории (средний тренд)	20 974,3	19 622,4	2,5	0,8
Максимальный тренд ОФП	21 398,8	19 874,1	0,5	-0,5
Минимальный тренд ОФП	20 505,8	19 313,2	4,7	2,3
Факт	21 516,3	19 773,1		

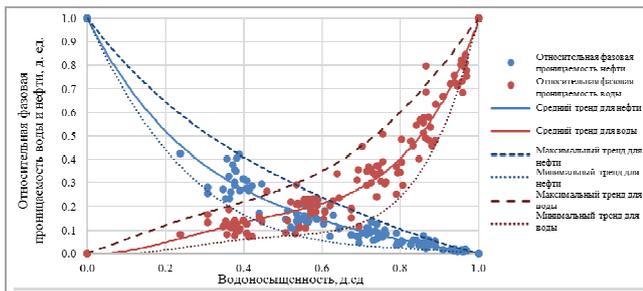


Рис. 14. Относительные фазовые проницаемости для нефти и воды

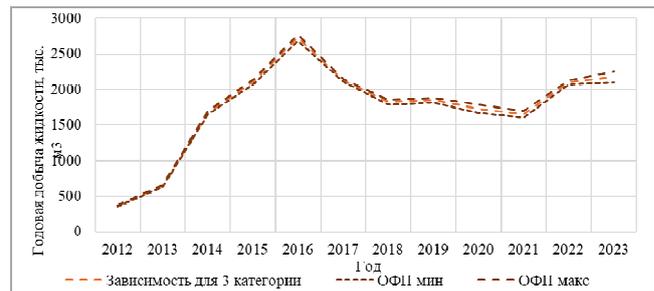


Рис. 15. Сравнение степени влияния формы кривых ОФП в гидродинамической модели на динамику добычи жидкости



Рис. 16. Сравнение степени влияния формы кривых ОФП в гидродинамической модели на динамику добычи нефти

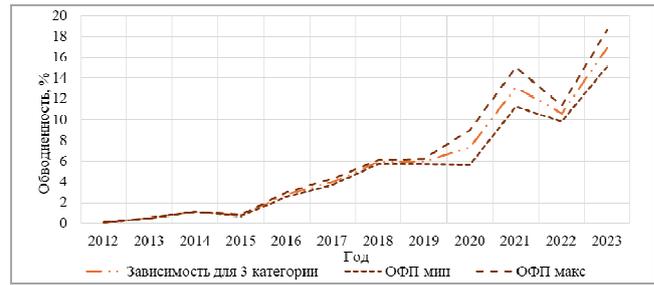


Рис. 17. Сравнение степени влияния формы кривых ОФП в гидродинамической модели на обводненность

При анализе системы разработки залежи данного месторождения предложен комплекс мероприятий, позволяющих снизить риски преждевременных прорывов воды по добывающим скважинам, включающий выполнение ремонтно-изоляционных работ на скважинах месторождения с высокой динамикой обводненности, выполнение на ряде добывающих скважин дострелов пропластков, не характеризующихся прорывами воды в зонах вторичных изменений, и т.д.

Результаты прогнозных расчетов приведены на рис. 18 и в табл. 11.

На рис. 18 и в табл. 11 можно наблюдать, что в результате реализации в геолого-гидродинамической модели методики выявления и распределения суперколлектора, а также предложения различных геолого-технологических мероприятий, направленных на корректировку действующей системы разработки в условиях развития интервалов суперколлекторов, удалось добиться снижения обводненности продукции к 2034 г. на 10 % и увеличить добычу нефти на 750 тыс. м³, что, в свою очередь, ведет к увеличению рентабельности эксплуатации объекта.

Сравнение накопленных показателей за 10 лет прогноза при базовой системе разработки и с учетом дополнительных мероприятий, направленных на взаимодействие с суперколлектором

Метод задания проницаемости	Накопленная добыча жидкости, тыс. м ³	Накопленная добыча нефти, тыс. м ³	Обводненность, %
Базовый расчет	14 820,6	10 018,7	43,2
Расчет с предложенными мероприятиями	14 762,6	10 768,8	37,2
Дополнительная добыча флюида / изменение обводненности	-58	+ 750,1	-10

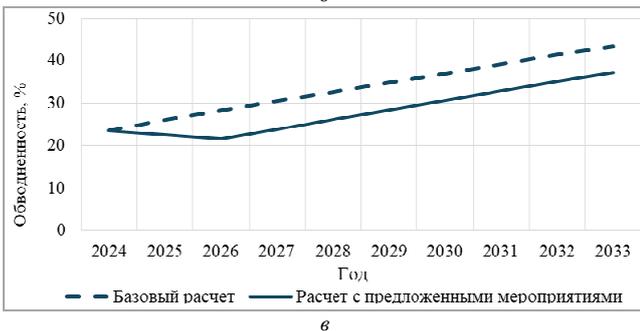
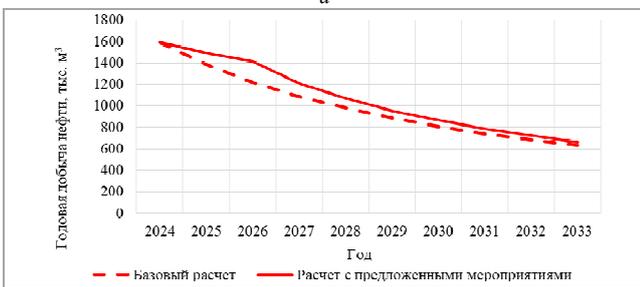


Рис. 18. Сравнение динамики добычи нефти (а–в) на прогнозе при базовой системе разработки и с учетом дополнительных мероприятий, направленных на взаимодействие с суперколлектором

Заключение

В исследовании предложен подход к определению высокопроницаемых интервалов на основе алгоритмов машинного обучения. Наиболее точным для прогнозирования высокопроницаемых интервалов является алгоритм градиентного бустинга. Для улучшения адаптации модели по истории разработки при прогнозировании высокопроницаемых интервалов предлагается использовать модель, обученную по данным каротажа и керн (реализация Р50). Для учета рисков,

Библиографический список

1. Diagenetic process and their effect on reservoir quality in Miocene carbonate reservoir Offshore, Sarawak, Malaysia / H.T. Janjubah, A.M.A. Salim, D. Ghosh, A. Wahid // In Proceedings of the International Conference on Integrated Petroleum Engineering and Geosciences. – Singapore, 2016. DOI: 10.1007/978-981-10-3650-7_48
2. Farzaneh, S.A. Using diagenetic processes in facies modeling of a carbonate reservoir / S.A. Farzaneh, A.A. Dehghan, A. Lakzaie // Energy Sources, Part A: Recovery, Utilization, and Environmental Effects. – 2013. – No. 35 (6). – P. 516–528. DOI: 10.1080/15567036.2010.504946
3. Study of the influence of nonlinear dynamic loads on elastic modulus of carbonate reservoir rocks / E. Riabokon, M. Turbakov, E. Kozhevnikov, V. Poplygin, M. Guzev // Energies. – 2021. – Vol. 14, no. 24. DOI 10.3390/en14248559
4. Progress of research on dolomitization and dolomite reservoir / Q. Huang, W. Liu, Y. Zhang, S. Shi, K. Wang // Advances in Earth Science. – 2015. – No. 30 (5). – P. 539. DOI: 10.11867/j.issn.1001-8166.2015.05.0539
5. A review of development methods and EOR technologies for carbonate reservoirs / Z.X. Xu., S.Y. Li, B.F. Li, D.Q. Chen, Z.Y. Liu, Z.M. Li // Petroleum Science. – 2020. – No. 17. – P. 990–1013. DOI: 10.1007/s12182-020-00467-5.

связанных с высокопроницаемыми интервалами, при бурении новых скважин рекомендуется использовать модель, обученную только по данным каротажа (реализация Р10). На основе анализа данных ГИС до перфорации модель может предсказать все возможные интервалы суперколлектора. В случае нагнетательной скважины это может являться основанием для отказа от перфорации высокопроницаемых интервалов.

Моделирование высокопроницаемых интервалов было выполнено в объеме резервуара, при этом было проведено многовариантное прогнозирование для уточнения свойств участков модели, соответствующих высокопроницаемым зонам. Подход включал анализ результатов классификации образцов керн методом DRT в сочетании с расчетом *t*-критерия Стьюдента, что позволило определить петрофизическую зависимость, наилучшим образом описывающую взаимосвязь пористости и проницаемости для зон суперколлекторов. После адаптации модели по истории разработки расхождения в накопленной добыче жидкости составили 2,5 %, а в накопленной добыче нефти – 0,8 %. Было установлено, что абсолютная проницаемость суперколлектора является наиболее значимым параметром при адаптации модели, в то время как кривые относительной проницаемости вносят минимальный вклад в результаты адаптации. Применение кривых относительной проницаемости с максимальным трендом в интервалах суперколлектора позволило снизить отклонение накопленной добычи жидкости с 2,5 до 0,5 %, а накопленной добычи нефти – с 0,8 до 0,5 %. Таким образом, для прогнозирования была использована наиболее консервативная кривая относительной проницаемости. Влияние кривой относительной проницаемости было минимальным из-за низкой текущей обводненности месторождения (менее 11 %), однако на более поздних стадиях разработки влияние кривой может быть более значительным.

На основе прогнозного анализа на модели с высокопроницаемыми интервалами предложен ряд мероприятий для снижения рисков прорыва воды в высокопроницаемых интервалах. По прогнозам, эти мероприятия позволят дополнительно получить 750 тыс. м³ нефти.

Представленный в данном исследовании подход позволяет анализировать и управлять разработкой сложного карбонатного коллектора с учетом вторичных изменений коллекторских свойств. Это значительно повышает геологическую точность процесса адаптации модели по истории и позволяет прогнозировать возможные прорывы воды из-за наличия суперколлектора.

6. Щербаков, А.А. Оценка эффективности мероприятий по интенсификации добычи нефти (на примере месторождений Соликамской депрессии) / А.А. Щербаков, Г.П. Хижняк, В.И. Галкин // Геология, геофизика и разработка нефтяных и газовых месторождений. – 2019. – № 2. – С. 70–73. DOI: 10.30713/2413-5011-2019-2-70-73
7. Ерофеев, А.А. Оценка условий применения методов обработки кривых восстановления давления скважин в карбонатных коллекторах / А.А. Ерофеев, И.Н. Пономарева, М.С. Турбаков // Инженер-нефтяник. – 2011. – № 3. – С. 12–15.
8. Production optimization for water flooding in fractured-vuggy carbonate reservoir—From laboratory physical model to reservoir operation / B. Yang, J. He, D. Lyu, H. Tang, J. Zhang, X. Li, J. Zhao // Journal of Petroleum Science and Engineering. – 2020. – No. 184. – P. 106520. DOI: 10.1016/j.petrol.2019.106520
9. Mechanistic Study and Optimization of High Water Cut Phase Management Strategies in Fracture-Vuggy Carbonate Reservoirs with Bottom Water / M. Zhao, X. Xin, G. Yu, R. Hu, Y. Gong // Processes. – 2023. – No. 11. – P. 3135. DOI: 10.3390/pr11113135
10. Waterflooding in giant carbonate reservoir: successes and challenges / S. Mahmood, P. Salazar, X. Zhao, M. Pointing, A. Sayed // In Proceedings of the Abu Dhabi International Petroleum Exhibition and Conference. – Abu Dhabi, UAE, 2017. DOI: 10.2118/188532-MS
11. Integrated Waterflooding Effect Evaluation Methodology for Carbonate Fractured-Vuggy Reservoirs Based on the Unascertained Measure—Mahalanobis Distance Theory / Z. Su, S. Gao, Z. Li, T. Li, N. Kang // Processes. – 2024. – No. 12. – P. 274. DOI: 10.3390/pr12020274
12. Jiao, F. Practice and knowledge of volumetric development of deep fractured-vuggy carbonate reservoirs in Tarim basin NW China / F. Jiao // Petroleum Exploration and Development. – 2019. – No. 46 (3). – P. 576–582. DOI: 10.1016/S1876-3804(19)60037-6
13. Dehghani, K. Modeling of waterflood in a vuggy carbonate reservoir / K. Dehghani, K.A. Edwards, P.M. Harris // In Proceedings of the SPE Annual Technical Conference and Exhibition. – San Antonio, Texas, 1997. DOI: 10.2118/38567-MS
14. Cho, Y. Stochastic discrete fracture network modeling in shale reservoirs via integration of seismic attributes and petrophysical data / Y. Cho // Interpretation. – 2021. – No. 9 (4). – P. SG47–SG58. DOI: 10.1190/INT-2020-0210.1
15. Impact and lessons of using high permeability streaks in history matching a giant offshore Middle East carbonate reservoir / K.M. Brantferger, G.S. Kompanik, H.M. Al-Jenaibi, W.S. Dodge, H. Patel // In Proceedings of the Abu Dhabi International Petroleum Exhibition and Conference. – Abu Dhabi, United Arab Emirates, 2012. DOI: 10.2118/161426-MS
16. High Permeability Streaks Characterisations in Middle East Carbonate / E. Poli, C. Maza, A. Virgone, F. Gisquet, C. Fraisse, P. Cecile // In Proceedings of the International Petroleum Technology Conference. – Doha, Qatar, 2009. DOI: 10.2523/IPTC-13385-ABSTRACT
17. Using Machine Learning to Capture High-Permeability Streaks in Reservoir Models / S. Manish Kumar, P. Humberto, E.J. Obeida, B.J. Houcine, K.K. Chakib, M. Hussein // In Proceedings of the ADIPEC. – Abu Dhabi, UAE, 2022. DOI: 10.2118/211661-MS
18. A systematic review of data science and machine learning applications to the oil and gas industry / Z. Tariq, M.S. Aljawad, A. Hasan, M. Murtaza, E. Mohammed, A. El Husseiny, S. Alarifi, M. Mahmoud, A. Abdurraheem // Journal of Petroleum Exploration and Production Technology. – 2021. – No. 11. – P. 4339–4374. DOI: 10.1007/s13202-021-01302-2
19. Choubey, S. Artificial intelligence techniques and their application in oil and gas industry / S. Choubey, G.P. Karmakar // Artificial Intelligence Review. – 2021. – No. 54 (5). – P. 3665–3683. DOI: 10.1007/s10462-020-09935-1
20. An Anomaly Detection Model for Oil and Gas Pipelines Using Machine Learning / S.S. Aljameel, D.M. Alomari, S. Alismail, F. Khawaher, A.A. Alkudhair, F. Aljbran, R.M. Alzannan // Computation. – 2022. – No. 10. – P. 138. DOI: 10.3390/computation10080138
21. Application of machine learning and artificial intelligence in oil and gas industry / A. Sircar, K. Yadav, K. Rayavarapu, N. Bist, H. Oza // Petroleum Research. – 2021. – No. 6 (4). – P. 379–391. DOI: 10.1016/j.ptres.2021.05.009
22. Fluid and lithofacies prediction based on integration of well-log data and seismic inversion: A machine-learning approach / L. Zhao, C.Zou, Y. Chen, W. Shen, Y. Wang, H. Chen, J. Geng // Geophysics. – 2021. – No. 86 (4). – P. M151–M165. DOI: 10.1190/geo2020-0521.1
23. Machine learning based fluids and lithofacies prediction based on the integration of well logging data and seismic inversion / C. Zou, L. Zhao, Y. Chen, Y. Wang // In Proceedings of the SEG 2020 Workshop: 2nd SEG Borehole Geophysics. – 2020. DOI: 10.1190/bhgp2020-32.1
24. Talebkeikhah, M. A comparison of machine learning approaches for prediction of permeability using well log data in the hydrocarbon reservoirs / M. Talebkeikhah, Z. Sadeqhtabaghi, M. Shabani // Journal of Human, Earth, and Future. – 2021. – No. 2. – P. 82–99. DOI: 10.28991/HEF-2021-02-02-01
25. Wood, D.A. Predicting porosity, permeability and water saturation applying an optimized nearest-neighbour, machine-learning and data-mining network of well-log data / D.A. Wood // Journal of Petroleum Science and Engineering. – 2020. – No. 184. – P. 106587. DOI: 10.1016/j.petrol.2019.106587
26. Miah, M.I. Log data-driven model and feature ranking for water saturation prediction using machine learning approach / M.I. Miah, S. Zendejboudi, S. Ahmed // Journal of Petroleum Science and Engineering. – 2020. – No. 194. – P. 107291. DOI: 10.1016/j.petrol.2020.107291
27. Bestagini, P. A machine learning approach to facies classification using well logs / P. Bestagini, V. Lipari, S. Tubaro // In Proceedings of the SEG International Exposition and Annual Meeting. – Houston, Texas, 2017. DOI: 10.1190/segam2017-17729805.1
28. Salehi, S.M. Automatic identification of formation lithology from well log data: a machine learning approach / S.M. Salehi, B. Honarvar // Journal of Petroleum Science Research. – 2014. – No. 3. – P. 73–82. DOI: 10.14355/jpsr.2014.0302.04
29. Well-Logging based lithology prediction using Machine Learning / Y. Meshalkin, A. Shakirov, D. Orlov, D. Koroteev // Data Science in Oil & Gas. – 2020. – No. 2020 (1). – P. 1–5. DOI: 10.3997/2214-4609.202054010
30. A machine-learning-based approach to assistive well-log correlation / S. Brazell, A.C. Bayeh, M. Ashby, D. Burton // Petrophysics. – 2019. – No. 60 (4). – P. 469–479. DOI: 10.30632/PJV60N4-2019a1
31. Application of Machine Learning for Lithofacies Prediction and Cluster Analysis Approach to Identify Rock Type / M. Hussain, S. Liu, U. Ashraf, M. Ali, W. Hussain, N. Ali, A. Anees // Energies. – 2022. – No. 15. – P. 4501. DOI: 10.3390/en15124501
32. Permeability Prediction Using Rock-Typing, Flow Zone Indicator and Machine Learning Techniques in a Brownfield Offshore Malaysia / B. Kantaatmadja, F. Kasim, W.N.S. Zainudin, E. Elsebakhi, E. Jr, A. Ali // In Proceedings of the International Petroleum Technology Conference, Virtual. – 2021. DOI: 10.2523/IPTC-21436-MS
33. Al Khalifah, H. Permeability prediction and diagenesis in tight carbonates using machine learning techniques / H. Al Khalifah, P.W.J. Glover, P. Lorinczi // Marine and Petroleum Geology. – 2020. – No. 112. – P. 104096. DOI: 10.1016/j.marpetgeo.2019.104096
34. Alameedy, U.S. Evaluating machine learning techniques for carbonate formation permeability prediction using well log data / U.S. Alameedy, A.T. Almomen, N. Abd // The Iraqi Geological Journal. – 2023. – No. 56. – P. 175–187. DOI: 10.46717/igj.56.1D.14ms-2023-4-23
35. High Permeability Streak Identification and Modelling Approach for Carbonate Reservoir / D. Shirinkin, A. Kochnev, S. Krivoshechekov, I. Putilov, A. Botalov, N. Kozmyrev, E. Ozhgibesov // Energies. – 2024. – No. 17. – P. 236. DOI: 10.3390/en17010236
36. Application of gradient boosting regression model for the evaluation of feature selection techniques in improving reservoir characterisation predictions / D. Othcher, T. Ganat, J. Ojero, B.N. Tackie-Otoo, M. Taki // Journal of Petroleum Science and Engineering. – 2022. – No. 208. – P. 109244. DOI: 10.1016/j.petrol.2021.109244
37. Abbas, M.A. Improving permeability prediction in carbonate reservoirs through gradient boosting hyperparameter tuning / M.A. Abbas, W.J. Al-Mudhafar, D.A. Wood // Earth Science Informatics. – 2023. – No. 16 (4). – P. 3417–3432. DOI: 10.1007/s12145-023-01099-0
38. Rahimi, M. Reservoir facies classification based on random forest and geostatistics methods in an offshore oilfield / M. Rahimi, M.A. Riahi // Journal of Applied Geophysics. – 2022. – No. 201. – P. 104640. DOI: 10.1016/j.jappgeo.2022.104640
39. Amagada, P.U. An Inferable Machine Learning Approach for Reservoir Lithology Characterization Using Drilling Data / P.U. Amagada // In Proceedings of the SPE Annual Technical Conference and Exhibition. – San Antonio, Texas, USA, 2023. DOI: 10.2118/217485-STU
40. A systematic machine learning method for reservoir identification and production prediction / W. Liu, Z. Chen, Y. Hu, L. Xu // Petroleum Science. – 2023. – No. 20 (1). – P. 295–308. DOI: 10.1016/j.petsci.2022.09.002
41. Li, W. Machine learning and data analytics for geoscience applications—Introduction / W. Li, W. Hu, A. Abubakar // Geophysics. – 2020. – No. 85 (4). – P. WAI–WAIi. DOI: 10.1190/geo2020-0518-spsintro.1
42. A mini-review of machine learning in big data analytics: Applications, challenges, and prospects / I.K. Nti, J.A. Quarcoo, J. Aning, G.K. Fosu // Big Data Mining and Analytics. – 2022. – No. 5 (2). – P. 81–97. DOI: 10.26599/BDMA.2021.9020028
43. Maganathan T., Senthilkumar S., Balakrishnan V. Machine learning and data analytics for environmental science: a Review, Prospects and Challenges / T. Maganathan, S. Senthilkumar, V. Balakrishnan // IOP Conference Series: Materials Science and Engineering. – 2020. – No. 955 (1). – P. 012107. DOI: 10.1088/1757-899X/955/1/012107
44. Enhanced Reservoir Description: Using Core and Log Data to identify Hydraulic (Flow) Units and Predict Permeability in Uncored Intervals/Wells / J.O. Amaefule, M. Altunbay, D. Tiab, D. Kersey, D. Keelan // In Proceedings of the SPE Annual Technical Conference and Exhibition. – Houston, Texas, 1993. DOI: 10.2118/26436-MS
45. Garrouh, A.A. Exploring the link between the flow zone indicator and key open-hole log measurements: An application of dimensional analysis / A.A. Garrouh, A.A. Al-Sultan // Petroleum geoscience. – 2019. – No. 25. – P. 219–234. DOI: 10.1144/petgeo2018-035

References

1. Janjuhah H.T., Salim A.M.A., Ghosh D., Wahid A. Diagenetic process and their effect on reservoir quality in Miocene carbonate reservoir Offshore, Sarawak, Malaysia. In *Proceedings of the International Conference on Integrated Petroleum Engineering and Geosciences*. Singapore, 2016. DOI: 10.1007/978-981-10-3650-7-48
2. Farzaneh S.A., Dehghan A.A., Lakzaie A. Using diagenetic processes in facies modeling of a carbonate reservoir. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 2013, no. 35 (6), pp. 516–528. DOI: 10.1080/15567036.2010.504946
3. Riabokon E., Turbakov M., Kozhevnikov E., Poplygin V., Guzev M. Study of the influence of nonlinear dynamic loads on elastic modulus of carbonate reservoir rocks. *Energies*, 2021, vol. 14, no. 24. DOI: 10.3390/en14248559
4. Huang Q., Liu W., Zhang Y., Shi S., Wang K. Progress of research on dolomitization and dolomite reservoir. *Advances in Earth Science*, 2015, no. 30 (5), 539 p. DOI: 10.11867/j.issn.1001-8166.2015.05.0539
5. Xu Z.X., Li S.Y., Li B.F., Chen D.Q., Liu Z.Y., Li Z.M. A review of development methods and EOR technologies for carbonate reservoirs. *Petroleum Science*, 2020, no. 17, pp. 990–1013. DOI: 10.1007/s12182-020-00467-5.
6. Shcherbakov A.A., Khizhniak G.P., Galkin V.I. Otsenka effektivnosti meropriyatii po intensifikatsii dobychi nefi (na primere mestorozhdenii Solikamskoi depressii) [Effectiveness evaluation of oil production stimulation measures (on the example of the Solikamsk depression fields)]. *Geologiya, geofizika i razrabotka nefiannykh i gazovykh mestorozhdenii*, 2019, no. 2, pp. 70–73. DOI: 10.30713/2413-5011-2019-2-70-73

7. Erofeev A.A., Ponomareva I.N., Turbakov M.S. Otsenka uslovii primeneniia metodov obrabotki krivyykh vosstanovleniia davleniia skvazhin v karbonatnykh kollektorakh [Evaluation of the application conditions for methods of processing well pressure recovery curves in carbonate reservoirs]. *Inzhener-neftianik*, 2011, no. 3, pp. 12-15.
8. Yang B., He J., Lyu D., Tang H., Zhang J., Li X., Zhao J. Production optimization for water flooding in fractured-vuggy carbonate reservoir-From laboratory physical model to reservoir operation. *Journal of Petroleum Science and Engineering*, 2020, no. 184, 106520 p. DOI: 10.1016/j.petrol.2019.106520
9. Zhao M., Xin X., Yu G., Hu R., Gong Y. Mechanistic Study and Optimization of High Water Cut Phase Management Strategies in Fracture-Vuggy Carbonate Reservoirs with Bottom Water. *Processes*, 2023, no. 11, 3135 p. DOI: 10.3390/pr11113135
10. Mahmood S., Salazar P., Zhao X., Pointing M., Sayed A. Waterflooding in giant carbonate reservoir; successes and challenges. In *Proceedings of the Abu Dhabi International Petroleum Exhibition and Conference*. Abu Dhabi, UAE, 2017. DOI: 10.2118/188532-MS
11. Su Z., Gao S., Li Z., Li T., Kang N. Integrated Waterflooding Effect Evaluation Methodology for Carbonate Fractured-Vuggy Reservoirs Based on the Unascertained Measure-Mahalanobis Distance Theory. *Processes*, 2024, no. 12, 274 p. DOI: 10.3390/pr12020274
12. Jiao F. Practice and knowledge of volumetric development of deep fractured-vuggy carbonate reservoirs in Tarim basin NW China. *Petroleum Exploration and Development*, 2019, no. 46 (3), pp. 576-582. DOI: 10.1016/S1876-3804(19)60037-6
13. Dehghani K., Edwards K.A., Harris P.M. Modeling of waterflood in a vuggy carbonate reservoir. In *Proceedings of the SPE Annual Technical Conference and Exhibition*, San Antonio, Texas, 1997. DOI: 10.2118/38567-MS
14. Cho Y. Stochastic discrete fracture network modeling in shale reservoirs via integration of seismic attributes and petrophysical data. *Interpretation*, 2021, no. 9 (4), pp. SG47-SG58. DOI: 10.1190/INT-2020-0210.1
15. Brantferger K.M., Kompanik G.S., Al-Jenaibi H.M., Dodge W.S., Patel H. Impact and lessons of using high permeability streaks in history matching a giant offshore Middle East carbonate reservoir. In *Proceedings of the Abu Dhabi International Petroleum Exhibition and Conference*. Abu Dhabi, United Arab Emirates, 2012. DOI: 10.2118/161426-MS
16. Poli E., Maza C., Virgone A., Gisquet F., Fraisse C., Cecile P. High Permeability Streaks Characterisations in Middle East Carbonate. In *Proceedings of the International Petroleum Technology Conference*. Doha, Qatar, 2009. DOI: 10.2523/IPTC-13385-ABSTRACT
17. Manish Kumar S., Humberto P., Obeida E.J., Houcine B.J., Chakib K.K., Hussein M. Using Machine Learning to Capture High-Permeability Streaks in Reservoir Models. In *Proceedings of the ADIPEC*. Abu Dhabi, UAE, 2022. DOI: 10.2118/211661-MS
18. Tariq Z., Aljawad M.S., Hasan A., Murtaza M., Mohammed E., El Husseiny A., Alarifi S., M. Mahmoud, A. Abdurraheem A systematic review of data science and machine learning applications to the oil and gas industry. *Journal of Petroleum Exploration and Production Technology*, 2021, no. 11, pp. 4339-4374. DOI: 10.1007/s13202-021-01302-2
19. Choubey S., Karmakar G.P. Artificial intelligence techniques and their application in oil and gas industry. *Artificial Intelligence Review*, 2021, no. 54 (5), pp. 3665-3683. DOI: 10.1007/s10462-020-09935-1
20. Aljameel S.S., Alomari D.M., Alismail S., Khawaher F., Alkhudhair A.A., Aljbran F., Alzannan R.M. An Anomaly Detection Model for Oil and Gas Pipelines Using Machine Learning. *Computation*, 2022, no. 10, 138 p. DOI: 10.3390/computation10080138
21. Sircar A., Yadav K., Rayavarapu K., Bist N., Oza H. Application of machine learning and artificial intelligence in oil and gas industry. *Petroleum Research*, 2021, no. 6 (4), pp. 379-391. DOI: 10.1016/j.ptlrs.2021.05.009
22. Zhao L., Zou C., Chen Y., Shen W., Wang Y., Chen H., Geng J. Fluid and lithofacies prediction based on integration of well-log data and seismic inversion: A machine-learning approach. *Geophysics*, 2021, no. 86 (4), pp. M151-M165. DOI: 10.1190/geo2020-0521.1
23. Zou C., Zhao L., Chen Y., Wang Y. Machine learning based fluids and lithofacies prediction based on the integration of well logging data and seismic inversion. In *Proceedings of the SEG 2020 Workshop: 2nd SEG Borehole Geophysics*, 2020. DOI: 2020.10.1190/bhgp2020-32.1
24. Talebkeikhah M., Sadeghtabaghi Z., Shabani M. A comparison of machine learning approaches for prediction of permeability using well log data in the hydrocarbon reservoirs. *Journal of Human, Earth, and Future*, 2021, no. 2, pp. 82-99. DOI: 10.28991/HEF-2021-02-02-01
25. Wood D.A. Predicting porosity, permeability and water saturation applying an optimized nearest-neighbour, machine-learning and data-mining network of well-log data. *Journal of Petroleum Science and Engineering*, 2020, no. 184, 106587 p. DOI: 10.1016/j.petrol.2019.106587
26. Miah M.I., Zendeheboudi S., Ahmed S. Log data-driven model and feature ranking for water saturation prediction using machine learning approach. *Journal of Petroleum Science and Engineering*, 2020, no. 194, 107291 p. DOI: 10.1016/j.petrol.2020.107291
27. Bestagini P., Lipari V., Tubaro S. A machine learning approach to facies classification using well logs. In *Proceedings of the SEG International Exposition and Annual Meeting*. Houston, Texas, 2017. DOI: 10.1190/segam2017-17729805.1
28. Salehi S.M., Honarvar B. Automatic identification of formation lithology from well log data: a machine learning approach. *Journal of Petroleum Science Research* 2014, no. 3, pp. 73-82. DOI: 10.14355/jpsr.2014.0302.04
29. Meshalkin Y., Shakirov A., Orlov D., Koroteev D. Well-Logging based lithology prediction using Machine Learning. *Data Science in Oil & Gas*, 2020, no. 2020 (1), pp. 1-5. DOI: 10.3997/2214-4609.202054010
30. Brazell S., Bayeh A.C., Ashby M., Burton D. A machine-learning-based approach to assistive well-log correlation. *Petrophysics*, 2019, no. 60 (4), pp. 469-479. DOI: 10.30632/PJV60N4-2019a1
31. Hussain M., Liu S., Ashraf U., Ali M., Hussain W., Ali N., Anees A. Application of Machine Learning for Lithofacies Prediction and Cluster Analysis Approach to Identify Rock Type. *Energies*, 2022, no. 15, 4501 p. DOI: 10.3390/en15124501
32. Kantaatmadja B., Kasim F., Zainudin W.N.S., Elsebaki E., Jr E., Ali A. Permeability Prediction Using Rock-Typing, Flow Zone Indicator and Machine Learning Techniques in a Brownfield Offshore Malaysia. In *Proceedings of the International Petroleum Technology Conference, Virtual*, 2021. DOI: 10.2523/IPTC-21436-MS
33. Al Khalifah H., Glover P.W.J., Lorinczi P. Permeability prediction and diagenesis in tight carbonates using machine learning techniques. *Marine and Petroleum Geology*, 2020, no. 112, 104096 p. DOI: 10.1016/j.marpetgeo.2019.104096
34. Alameedy U.S., Almomen A.T., Abd N. Evaluating machine learning techniques for carbonate formation permeability prediction using well log data. *The Iraqi Geological Journal*, 2023, no. 56, pp. 175-187. DOI: 10.46717/igi.56.1D.14ms-2023-4-23
35. Shirinkin D., Kochnev A., Krivoshechekov S., Putilov I., Botalov A., Kozlyev N., Ozhgibesov E. High Permeability Streak Identification and Modelling Approach for Carbonate Reef Reservoir. *Energies*, 2024, no. 17, 236 p. DOI: 10.3390/en17010236
36. Otchere D., Ganat T., Ojoro J., Tackie-Otoo B.N., Taki M. Application of gradient boosting regression model for the evaluation of feature selection techniques in improving reservoir characterisation predictions. *Journal of Petroleum Science and Engineering*, 2022, No. 208, 109244 p. DOI: 10.1016/j.petrol.2021.109244
37. Abbas M.A., Al-Mudhafar W.J., Wood D.A. Improving permeability prediction in carbonate reservoirs through gradient boosting hyperparameter tuning. *Earth Science Informatics*, 2023, no. 16 (4), pp. 3417-3432. DOI: 10.1007/s12145-023-01099-0
38. Rahimi M., Riahi M.A. Reservoir facies classification based on random forest and geostatistics methods in an offshore oilfield. *Journal of Applied Geophysics*, 2022, no. 201, 104640 p. DOI: 10.1016/j.jappgeo.2022.104640
39. Amagada P.U. An Inferable Machine Learning Approach for Reservoir Lithology Characterization Using Drilling Data. In *Proceedings of the SPE Annual Technical Conference and Exhibition*. San Antonio, Texas, USA, 2023. DOI: 10.2118/217485-STU
40. Liu W., Chen Z., Hu Y., Xu L. A systematic machine learning method for reservoir identification and production prediction. *Petroleum Science*, 2023, no. 20 (1), pp. 295-308. DOI: 10.1016/j.ptsci.2022.09.002
41. Li W., Hu W., Abubakar A. Machine learning and data analytics for geoscience applications - Introduction. *Geophysics*, 2020, no. 85 (4), pp. WAI-WAii. DOI: 10.1190/geo2020-0518-spsintro.1
42. Nti I.K., Quarcoo J.A., Aning J., Fosu G.K. A mini-review of machine learning in big data analytics: Applications, challenges, and prospects. *Big Data Mining and Analytics*, 2022, no. 5 (2), pp. 81-97. DOI: 10.26599/BDMA.2021.9020028
43. Maganathan T., Senthilkumar S., Balakrishnan V. Machine learning and data analytics for environmental science: a Review, Prospects and Challenges. *IOP Conference Series: Materials Science and Engineering*, 2020, no. 955 (1), 012107 p. DOI: 10.1088/1757-899X/955/1/012107
44. Amaefule J.O., Altunbay M., Tiab D., Kersey D., Keelan D. Enhanced Reservoir Description: Using Core and Log Data to identify Hydraulic (Flow) Units and Predict Permeability in Uncored Intervals/Wells. In *Proceedings of the SPE Annual Technical Conference and Exhibition*. Houston, Texas, 1993. DOI: 10.2118/26436-MS
45. Garrouh A.A., Al-Sultan A.A. Exploring the link between the flow zone indicator and key open-hole log measurements: An application of dimensional analysis. *Petroleum geoscience*, 2019, no. 25, pp. 219-234. DOI: 10.1144/petgeo2018-035

Финансирование. Исследование выполнено в рамках гранта Российского научного фонда № 22-17-00111.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Вклад авторов равноценен.