

УДК 622.276
DOI: 10.18799/24131830/2025/1/4581
Шифр специальности ВАК: 2.8.4

Интеграция промысловых данных и применение методов машинного обучения для оценки состояния призабойной зоны карбонатных коллекторов

А.В. Соромотин¹, Д.А. Мартюшев²✉

¹ ООО "ЛУКОЙЛ-Инжиниринг", Россия, г. Пермь

² Пермский национальный исследовательский политехнический университет, Россия, г. Пермь

✉ martyshevd@inbox.ru

Аннотация. *Актуальность* разработки методики оперативной оценки фильтрационных свойств призабойной зоны пласта (проницаемость призабойной зоны пласта) обусловлена ростом доли трудноизвлекаемых запасов. Зачастую для эффективной разработки сложнопостроенных залежей применяют методы повышения нефтеотдачи и интенсификации добычи. В настоящее время целесообразность проведения геолого-технических мероприятий основывается на результатах интерпретации гидродинамических исследований скважин, позволяющих оценить состояние околоскважинной зоны. Недостатками данного метода исследований являются продолжительная остановка (как следствие, «недоборы» нефти) и повышенные риски необеспечения вывода скважин на режим. В связи с этим интеграция промысловых данных и применения машинного обучения для описания состояния призабойной зоны пласта могут оказать положительный эффект на своевременность проведения геолого-технических мероприятий и обеспечить максимизацию их эффективности в будущем. **Цель:** разработка методики прогнозирования проницаемости призабойной зоны пласта в условиях карбонатного коллектора с помощью подходов машинного обучения. **Методы:** статистические методы, решение задачи классификации с помощью методов машинного обучения. **Результаты.** Предложен подход для оперативной оценки проницаемости призабойной зоны пласта, основанный на статистическом анализе результатов интерпретации гидродинамических исследований (256 исследований) и эксплуатационных данных скважин нефтяного карбонатного объекта Пермского края. Для оценки проницаемости призабойной зоны пласта построена модель множественной линейной регрессии. С целью повышения статистических метрик регрессии проницаемости призабойной зоны пласта исследована зависимость данного параметра от удельного коэффициента продуктивности в условиях карбонатного коллектора и произведено деление на кластеры. Для определения параметров, оказывающих преобладающее влияние на прогнозируемую величину, использовалась библиотека SHAP. Для выполнения задачи классификации кластеров по исходным данным применена техника машинного обучения – метод опорных векторов. Дифференцированно построены модели регрессии для каждого кластера. Использование данного подхода позволило повысить коэффициент детерминации с 0,76 до 0,96 и уменьшить среднюю абсолютную ошибку прогнозирования проницаемости призабойной зоны пласта с 0,018 до 0,007 мкм². Таким образом, авторами предложена методика прогнозирования проницаемости призабойной зоны пласта с помощью статистических методов на основе предварительной кластеризации исходных данных и их классификации подходами машинного обучения.

Ключевые слова: карбонатный коллектор, машинное обучение, метод опорных векторов, проницаемость, призабойная зона

Благодарности. Исследования выполнены при поддержке Министерства науки и высшего образования Российской Федерации (проект № FSNM-2023-0005).

Для цитирования: Соромотин А.В., Мартюшев Д.А. Интеграция промысловых данных и применение методов машинного обучения для оценки состояния призабойной зоны карбонатных коллекторов // Известия Томского политехнического университета. Инжиниринг георесурсов. – 2025. – Т. 336. – № 1. – С. 50–60. DOI: 10.18799/24131830/2025/1/4581

UDC 622.276

DOI: 10.18799/24131830/2025/1/4581

Integration of field data and application of machine learning methods to assess the condition of the near-wellbore zone of carbonate reservoirs

A.V. Soromotin¹, D.A. Martyushev²✉

¹ LLC «LUKOIL-Engineering», Perm, Russian Federation

² Perm National Research Polytechnic University, Perm, Russian Federation

✉martyushevd@inbox.ru

Abstract. Relevance. Increase in the share of hard-to-recover reserves. Often, for the effective development of complex reservoirs, methods of enhanced oil recovery and production intensification are used. Currently, the feasibility of carrying out geological and technical measures is based on the results of interpretation of well tests, which allows assessing the condition of the near-wellbore zone. The disadvantages of this research method are a long shutdown (as a result, “shortfalls” of oil) and increased risks of failure to bring wells into operation. In this regard, the integration of field data and the use of machine learning to describe the state of the near-wellbore zone can have a positive effect on the timeliness of geological and technical activities and ensure maximization of their effectiveness in the future. **Aim.** To develop a methodology for increasing the accuracy of the near-wellbore zone permeability prediction of carbonate reservoirs based on the use of machine learning methods. **Methods.** Statistical methods, solving the classification problem using machine learning methods. **Results.** This paper proposes an approach for quickly assessing the permeability of the near-wellbore zone, based on a statistical analysis of the results of interpretation of hydrodynamic studies (256 studies) and operational data from wells of an oil carbonate reservoir in the Perm Krai. To assess near-wellbore zone permeability, a multiple linear regression model was built. In order to improve the statistical metrics of regression of the near-wellbore zone permeability, the dependence of this parameter on the specific productivity coefficient in the conditions of a carbonate reservoir was studied and divided into clusters. The SHAP library was used to identify significant parameters on the predicted value. To perform the task of classifying clusters based on source data, the authors have used a machine learning technique – support vector machine and constructed differentially the regression models for each cluster. Using of this approach made it possible to increase the coefficient of determination from 0.76 to 0.96 and reduce the average absolute error in predicting the near-wellbore zone permeability from 0.018 to 0.007 μm^2 . Thus, the authors proposed a methodology for predicting the near-wellbore zone permeability using statistical methods based on preliminary clustering of the initial data and their classification using machine learning approaches.

Keywords: carbonate reservoir, machine learning, support vector machine, permeability, near-wellbore zone

Acknowledgements. The research was funded by the Ministry of Science and Higher Education of the Russian Federation (Project No. FSNM-2023-0005).

For citation: Soromotin A.V., Martyushev D.A. Integration of field data and application of machine learning methods to assess the condition of the near-wellbore zone of carbonate reservoirs. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*, 2025, vol. 336, no. 1, pp. 50–60. DOI: 10.18799/24131830/2025/1/4581

Введение

Распределение карбонатных коллекторов составляет 20 % от общей площади мировых осадочных пород. Запасы нефти и газа, приуроченные к данным отложениям, составляют приблизительно 70 %, а доказанные извлекаемые запасы – около 50 % мировых ресурсов [1]. Однако добыча углеводородов и выбор технологий для эффективной разработки характеризуются рядом сложностей и проблем [2–4]. Неоднородность и расчленённость карбонатных отложений оказывают негативное влияние на выработку запасов. В большинстве случаев наблюдается недостаточное влияние нагнетательных скважин на добывающие ввиду сложностей пустотного пространства и распределения

проницаемости в пределах залежи [5–7]. Наличие в карбонатных коллекторах естественной трещиноватости является одной из причин изменчивости продуктивных характеристик скважин. Изучению данных вопросов посвящены научные работы [8–13]. В сравнении с песчаниками карбонатные коллекторы обладают высокой степенью гетерогенности. Наличие вторичных видов пустотности имеет существенное влияние на значения пористости и проницаемости пород-коллекторов и, как следствие, оказывает первоочередное влияние на эффективность добычи. Важной особенностью, характеризующей эффективность разработки данного типа коллектора, является влияние забойного и пластового давлений на проницаемость по нефти

и продуктивность скважин [14, 15]. В работе [16] исследовано влияние геолого-физических характеристик карбонатных коллекторов со сложным геологическим строением на условия притока углеводородов. Причиной снижения проницаемости карбонатных коллекторов может являться смыкание трещин вследствие упругих и пластических деформаций породы при повышении эффективного давления [17].

В последнее время широко исследуются и совершенствуются методы прогнозирования проницаемости гетерогенных карбонатных коллекторов с помощью подходов машинного обучения на основе каротажных данных [18–21]. Кроме того, в ряде научных работ описаны лабораторные исследования на образцах керна по определению зависимостей проницаемости от изменения эффективного давления [22–25]. Авторами работы [26] выполнено прогнозирование проницаемости призабойной зоны пласта (ПЗП) при волновом воздействии. Все данные методы и подходы основаны либо на непосредственном взаимодействии с объектом исследования, либо на определении статического значения без учета динамических составляющих разработки объекта. В настоящее время почти не исследованы косвенные методы определения фильтрационных параметров на основе эксплуатационных параметров.

Таким образом, контроль за изменением проницаемости (в призабойной и удаленной зонах) карбонатного коллектора является важным элементом эффективной разработки месторождений углеводородов. Особенно стоит отметить, что динамическая оценка проницаемости ПЗП является критерием и одним из основных параметров, влияющих на эффективность геолого-технических мероприятий [27].

Авторами данной работы разработан подход повышения точности прогнозирования проницаемости ПЗП статистическими методами в условиях карбонатного коллектора с помощью предварительной кластеризации исходных данных и дальнейшей их классификации с помощью методов машинного обучения. Предлагается деление исходных данных (текущее забойное давление, эффективная нефтенасыщенная толщина, пористость, дебит жидкости, обводненность) на кластеры для повышения метрик статистических моделей проницаемости призабойной зоны пласта.

Материалы и методы

Для решения поставленной задачи привлечены данные 256 гидродинамических исследований скважин (ГДИС) карбонатного объекта нефтяного месторождения Пермского края. Кривые восстановления давления (КВД) обработаны в программ-

ном продукте KAPPA Workstation с определением скин-фактора (S) и проницаемости призабойной/удаленной зон пласта ($k_{\text{пзп}}/k_{\text{узп}}$). Также интерпретированы 15 индикаторных диаграмм с определением проницаемости призабойной зоны пласта ($k_{\text{пзп}}$). В качестве исходных данных использованы следующие параметры:

- забойное давление ($P_{\text{заб}}$), диапазон значений от 2,94 до 17,48 МПа;
- давление пластовое ($P_{\text{пл}}$), диапазон значений от 5,96 до 21,64 МПа;
- дебит жидкости (Q), диапазон значений от 0,1 до 107 м³/сут.;
- эффективная нефтенасыщенная толщина пласта (h), диапазон значений от 1 до 29,6 м;
- обводненность (W), диапазон значений от 1 до 99,9 %;
- пористость (m), диапазон значений от 7,4 до 19,4 %;
- удельный коэффициент продуктивности ($\text{PROD} = \frac{Q}{(P_{\text{пл}} - P_{\text{заб}}) \cdot h}$), диапазон значений от 0,0088 до $3,56 \frac{\text{м}^3}{\text{сут} \cdot \text{м} \cdot \text{МПа}}$.

Построение моделей множественной линейной регрессии позволяет обеспечить поиск статистических связей с геолого-техническими показателями для прогнозирования исследуемого параметра (проницаемость ПЗП). Метод пошагового регрессионного анализа широко используется для решения различных производственно-технологических задач, особенно в условиях сложных многофакторных процессов [28–32]. При использовании данного подхода построена модель прогнозирования проницаемости ПЗП ($k_{\text{пзп}}$):

$$k_{\text{пзп}} = 0,008 + 0,056\text{PROD} + 0,0004W + 0,0003Q - 0,001P_{\text{пл}} - 0,001P_{\text{заб}} - 0,0003h + 0,00004m$$

R^2 : 0,571; 0,660; 0,673; 0,684; 0,688; 0,689; 0,689;
 стандартная ошибка составила 0,018 мкм²; уровень значимости менее 0,0001.

Для анализа параметров, влияющих на исследуемый параметр, построены графики зависимости проницаемости ПЗП от удельного коэффициента продуктивности и выделены три кластера (рис. 1, 2). Кластеры выделены визуально по линейной корреляции зависимости проницаемости ПЗП от удельного коэффициента продуктивности. Выдвинута гипотеза, что на основе кластеризации линейных зависимостей проницаемости ПЗП от удельного коэффициента продуктивности с помощью подходов машинного обучения получится осуществить учет вторичных факторов, например динамика фильтрационных параметров, ввиду изменения забойного давления, фазовых проницаемостей и влияния трещиноватости.




Рис. 1. Зависимость проницаемости ПЗП от удельного коэффициента продуктивности

Fig. 1. Dependence of the near-wellbore zone (NWBZ) permeability on productivity specific coefficient




Рис. 2. Зависимость проницаемости ПЗП от удельного коэффициента продуктивности (выделение 3 кластеров)

Fig. 2. Dependence of the NWBZ permeability on the productivity specific coefficient (allocation of 3 clusters)

Разделение выборки осуществлено для анализа влияния исходных параметров на значение проницаемости ПЗП в условиях карбонатного коллектора. Данная задача решалась с использованием библиотек

SHapley Additive exPlanations (SHAP), позволяющей выявить значимость каждого параметра.

Кроме того, дифференцированно построенные регрессионные модели для каждого кластера позволяют повысить статистические метрики для прогнозирования проницаемости околоскважинной зоны. Таким образом, предлагается классифицировать исходные данные на кластеры для более точного определения проницаемости ПЗП с помощью статистических моделей. Исходными данными для классификации кластера являются: забойное давление, эффективная нефтенасыщенная толщина, пористость, дебит жидкости, обводненность. Номер кластера является искомым параметром.

Решение задачи классификации осуществлено с помощью метода опорных векторов (SVM – support vector machine). Данный метод основан на идее поиска оптимальной гиперплоскости, которая разделяет исходные параметры.

Результаты

Определение параметров, оказывающих преобладающее влияние на отношение проницаемости ПЗП к удельному коэффициенту продуктивности, осуществлялось с помощью библиотеки SHAP, которая используется для интерпретации моделей машинного обучения. Таким образом, на основании модели классификации (градиентный бустинг) и данной библиотеки установлено, что обводненность является одним из наиболее значимых параметров, оказывающих влияние на формирование проницаемости ПЗП (значимость 0,48). Дополнительный промысловый анализ показал, что возможная причина снижения фильтрационных свойств исследуемых отложений и высокого влияния обводненности связана с особенностями закачиваемого агента: качество и его несовместимость с пластовыми водами в условиях карбонатного коллектора.

На рис. 3 представлен график сравнения фактических и прогнозных значений классификации исходных данных на кластеры. На вертикальной оси отмечены значения номера кластера (1, 2, 3). На горизонтальной оси 50 элементов тестовой выборки, по которой выполняется сравнение сходности модели, точность составила 84 % (рис. 3). В качестве дополнительной метрики качества модели добавлен показатель F1-score, который объединяет в себе два важных показателя: Precision (Точность), Recall (Полнота) и является более обоснованным в случае, когда классы не сбалансированы. F1-score составил 83,3 %.

Построенные дифференцированно для кластеров модели проницаемости ПЗП представлены ниже. На рис. 4 представлено сравнение фактических и прогнозных значений проницаемости ПЗП.




Рис. 3. Сравнение фактических и прогнозных значений классификации кластера на тестовой выборке
Fig. 3. Comparison of the actual and predicted values of cluster classification in a test sample

Кластер 1:

$$K_{ПЗП} = -0,00015 + 0,029PROD + 0,0000159W - 0,0000173Q + 0,00015P_{пл} - 0,000164P_{заб} + 0,0000009h - 0,000128m$$

$$R^2: 0,998; S: 0,0007 \text{ мкм}^2; p < 0,0001.$$

$$PROD, \frac{\text{м}^3}{\text{сут} \cdot \text{МПа} \cdot \text{м}}, \text{ диапазон } 0,009-3,6;$$

$$W, \%, \text{ диапазон } 1,0-99,9;$$

$$Q, \text{ м}^3/\text{сут}, \text{ диапазон } 0,1-66,4;$$

$$P_{пл}, \text{ МПа}, \text{ диапазон } 6,4-17,1;$$

$$P_{заб}, \text{ МПа}, \text{ диапазон } 3,2-10,2;$$

$$h, \text{ м}, \text{ диапазон } 1,0-22,2; m, \%, \text{ диапазон } 8,7-15,9.$$

Кластер 2:

$$K_{ПЗП} = -0,00093 + 0,0756PROD + 0,0000519W - 0,00003Q + 0,0001P_{пл} - 0,00118P_{заб} + 0,00007h + 0,00039m$$

$$R^2: 0,924; S: 0,007 \text{ мкм}^2; p < 0,0001.$$

$$PROD, \frac{\text{м}^3}{\text{сут} \cdot \text{МПа} \cdot \text{м}}, \text{ диапазон } 0,025-2,4;$$

$$W, \%, \text{ диапазон } 5,0-99,2;$$

$$Q, \text{ м}^3/\text{сут}, \text{ диапазон } 2,2-82,9;$$

$$P_{пл}, \text{ МПа}, \text{ диапазон } 5,96-21,6;$$

$$P_{заб}, \text{ МПа}, \text{ диапазон } 2,94-17,5;$$

$$h, \text{ м}, \text{ диапазон } 1,3-29,6; m, \%, \text{ диапазон } 7,4-15,9.$$

Кластер 3:

$$K_{ПЗП} = 0,00856 + 0,106PROD - 0,000048W + 0,000182Q - 0,001P_{пл} + 0,000798P_{заб} - 0,00037h + 0,000542m$$

$$R^2: 0,973; S: 0,007 \text{ мкм}^2; p < 0,0001.$$

$$PROD, \frac{\text{м}^3}{\text{сут} \cdot \text{МПа} \cdot \text{м}}, \text{ диапазон } 0,063-2,8;$$

$$W, \%, \text{ диапазон } 21,3-90,2;$$

$$Q, \text{ м}^3/\text{сут}, \text{ диапазон } 2,4-107,0;$$

$$P_{пл}, \text{ МПа}, \text{ диапазон } 7,05-20,6;$$

$$P_{заб}, \text{ МПа}, \text{ диапазон } 3,21-12,1;$$

$$h, \text{ м}, \text{ диапазон } 2,3-29,6; m, \%, \text{ диапазон } 7,6-19,4.$$




Рис. 4. Корреляционное поле прогнозных и фактических значений проницаемости ПЗП (дифференцировано для каждого кластера)
Fig. 4. Correlation field of predicted and actual values of NWBZ permeability (differentiated for each cluster)




Рис. 5. Распределение исходных параметров для каждого кластера

Fig. 5. Distribution of initial parameters for each cluster

Данные уравнения применимы для оперативно-го определения проницаемости ПЗП в условиях карбонатного объекта исследуемого месторождения Пермского края. Предлагаемый подход может быть тиражирован на другие объекты со статистически значимым количеством гидродинамических исследований.

Для каждой модели также рассчитаны статистические характеристики работоспособности. Средняя абсолютная ошибка проницаемости ПЗП по дифференцированным моделям составляет не более $0,007 \text{ мкм}^2$. Основным влияющим параметром является удельный коэффициент продуктивности. С помощью модели классификации SVM осуществляется анализ исходных параметров (забойное давление, эффективная нефтенасыщенная толщина, пористость, дебит жидкости, обводненность) и дальнейшая классификация принадлежности к кластеру. Выбор уравнения, на основе которого осуществляется расчет, производится путем использо-

вания модели SVM. Данный метод основан на идее поиска оптимальной гиперплоскости, которая разделяет исходные параметры. На рис. 5 представлены данные, которые включаются в модель SVM для обучения выбора кластера.

Обсуждение

Используемые на данный момент методы оценки состояния призабойной зоны опираются на интерпретацию гидродинамических исследований, особенностью которых является продолжительная остановка скважин, ведущая к недоборам и повышению рисков необеспечения вывода их на режим. На сегодняшний день при выборе методов воздействия на пласт руководствуются проницаемостью удаленной зоны пласта, которая определяется по данным ГДИС методами КВД/КВУ (кривая восстановления уровня), что является некорректным подходом. Стоит отметить, что по данным ГДИ методами КВД/КВУ осложнена оценка проницаемости

ПЗП прямым способом, она определяется только при обработке индикаторных диаграмм, которые проводятся не на всех скважинах фонда и только в период их опробования.

Методы КВД/КВУ обеспечивают определение проницаемости ПЗП за счет пересчета проницаемости удаленной зоны пласта (УЗП) в зависимости от дополнительного перепада давления вблизи ствола скважины, отражаемого в начальный период регистрации кривых восстановления давления. Данный принцип осложнен вторичными проблемами, например явлениями послепритока в скважину. Тем не менее исследование проведено на этих данных с целью нахождения корреляции проницаемости ПЗП с расчетным коэффициентом продуктивности. Нахождение статистической связи между рассматриваемыми параметрами обеспечивает обоснование достоверности данных интерпретации. Предлагаемый подход позволяет оценить проницаемость ПЗП без проведения ГДИС.

Мониторинг за изменением характеристик ПЗП является одной из основных задач, на основании которой принимаются решения о реализации, порой дорогостоящих, методов интенсификации, повышения нефтеотдачи пласта. Таким образом, оценка состояния и проницаемости призабойной зоны скважин является актуальной задачей, которая позволит более обоснованно подходить к подбору технологического режима работы, методов интенсификации добычи скважин и повышения нефтеотдачи пласта. Анализ мирового опыта показывает, что, несмотря на значительное влияние проницаемости ПЗП на эффективность вышеперечисленных мероприятий, задача ее оперативного определения и прогнозирования охвачена слабо и открыта для исследований.

В настоящей работе предложен подход прогнозирования проницаемости ПЗП в условиях карбонатного коллектора с помощью предварительной кластеризации исходных данных. Для каждого кластера построены статистические модели множественной линейной регрессии проницаемости ПЗП. Подходы и методы, представленные в работе, не затрагивались ранее научным сообществом и являются первым этапом по созданию комплексной системы по оценке состояния ПЗП на основе больших данных разработки нефтегазовых объектов.

На примере месторождения Пермского края разработан подход оперативной оценки проницаемости ПЗП. Использование удельного коэффициента продуктивности как основного параметра позволяет достаточно точно определять проницаемость ПЗП с помощью статистических методов. Исследование показало, что в условиях карбонатного коллектора наблюдался высокий разброс зависимости проницаемости ПЗП от удельного коэффициента продуктивности. Поэтому выдвинута гипотеза о влиянии вторичных факторов на данный параметр. Таким образом, в работе предложен подход повышения точности прогнозирования проницаемости ПЗП с помощью предварительной кластеризации исходных данных на основе линейной зависимости проницаемости ПЗП от удельного коэффициента продуктивности. Точность полученной модели классификации выделенных кластеров на основе методов машинного обучения составила 84 %. При использовании данного подхода коэффициент детерминации изменен с 0,76 до 0,96, средняя абсолютная ошибка проницаемости ПЗП уменьшена с 0,018 до 0,007 мкм².

В будущих исследованиях планируется исследование применения рекуррентных и сверточных искусственных нейронных сетей для оценки состояния ПЗП.

Выводы

1. Построена модель множественной линейной регрессии для прогнозирования проницаемости ПЗП скважин карбонатного объекта, характеризующаяся коэффициентом детерминации 0,76 и средней абсолютной ошибкой 0,018 мкм².
2. Исследовано влияние эксплуатационных и геологических параметров скважин на зависимость проницаемости ПЗП от удельного коэффициента продуктивности и установлен наиболее значимый – обводненность добываемой продукции.
3. Разработана методика прогнозирования проницаемости ПЗП с помощью статистических методов на основе предварительной кластеризации исходных данных и их классификации подходами машинного обучения. Использование данного подхода позволило повысить коэффициент детерминации с 0,76 до 0,96 и уменьшить среднюю абсолютную ошибку прогнозирования проницаемости ПЗП с 0,018 до 0,007 мкм².

СПИСОК ЛИТЕРАТУРЫ

1. Theories and practices of carbonate reservoirs development in China / Y. Li, Z. Kang, Z. Xue, S. Zheng // *Petroleum Exploration and Development*. – 2018. – Vol. 45. – Iss. 4. – P. 712–722. DOI: <https://doi.org/10.11698/PED.2018.04.12>
2. A novel hydromechanical coupled analysis for the fractured vuggy carbonate reservoir / F. Zhang, M. An, B. Yan, Y. Wang, Y. Han // *Computers and Geotechnics*. – 2019. – Vol. 106. – P. 68–82. DOI: <https://doi.org/10.1016/j.compgeo.2018.10.013>
3. Origin of carbonate minerals and impacts on reservoir quality of the Wufeng and Longmaxi Shale, Sichuan Basin / Y. Chen, J.-H. Zhao, Q.-H. Hu et al. // *Petroleum Science*. – 2023. – Vol. 20. – Iss. 6. – P. 3311–3336. DOI: <https://doi.org/10.1016/j.petsci.2023.08.012>

4. A fast method of waterflooding performance forecast for largescale thick carbonate reservoir / Y. Li, Q. Zhang, D. Wang, B. Song, P. Liu // *Journal of Petroleum Science and Engineering*. – 2020. – Vol. 192. – Article 107227. DOI: <https://doi.org/10.1016/j.petrol.2020.107227>
5. Kaminskaite I., Fisher Q.J., Michie E.A. Microstructure and petrophysical properties of deformation bands in high porosity carbonates // *Journal of Structural Geology*. – 2019. – Vol. 119. – P. 61–80. DOI: <https://doi.org/10.1016/j.jsg.2018.12.001>
6. Shedid A. Shedid. Vertical-horizontal permeability correlations using coring data // *Egyptian Journal of Petroleum*. – 2019. – Vol. 28. – P. 97–101. DOI: <https://doi.org/10.1016/j.ejpe.2018.12.007>
7. The effectiveness of flow salinity waterflooding in naturally fractured reservoirs / F.A. Aljuboori, J.H. Lee, K.A. Elraies, K.D. Stephen // *Journal of Petroleum Science and Engineering*. – 2020. – Vol. 191. – Article 107167. DOI: <https://doi.org/10.1016/j.petrol.2020.107167>
8. Cordero J.A.R., Sanchez E.C.M., Roehl D. Integrated discrete fracture and dual porosity – dual permeability models for fluid flow in deformable fractured media // *Journal of Petroleum Science and Engineering*. – 2019. – Vol. 175. – P. 644–653. DOI: <https://doi.org/10.1016/j.petrol.2018.12.053>
9. Özkaya S.I. Fracture modeling from borehole image logs and water invasion in carbonate reservoirs with layer-bound fractures and fracture corridors // *Journal of Petroleum Science and Engineering*. – 2019. – Vol. 179. – P. 199–209. DOI: <https://doi.org/10.1016/j.petrol.2019.04.052>
10. A new empirical model for enhancing well log permeability prediction, using nonlinear regression method: Case study from Hassi-Berkine oil field reservoir – Algeria / H.E. Belhouchet, M.S. Benzagouta, A. Dobbi, A. Alquraishi, J. Duplay // *Journal of King Saud University – Engineering Sciences*. – 2021. – Vol. 33. – P. 136–145. DOI: <https://doi.org/10.1016/j.jksues.2020.04.008>
11. Machine Learning Approach Based Study of Production Forecasting and Factors Influencing the Multiphase Flow through Surface Chokes / W. Kaleem, S. Tewari, M. Fogat, D.A. Martyushev // *Petroleum*. – 2024. – Vol. 10 (2). – P. 354–371. DOI: <https://doi.org/10.1016/j.petlm.2023.06.001>
12. A novel connectivity-based hierarchical model for multi-scale fracture system in carbonate reservoir simulation / Y. Guo, Y. Liang, J. Li, B. Gong // *Fuel*. – 2019. – Vol. 250. – P. 327–338. DOI: <https://doi.org/10.1016/j.fuel.2019.03.048>
13. Hamada G., Joseph V. Developed correlations between sound wave velocity and porosity, permeability and mechanical properties of sandstone core samples // *Petroleum Research*. – 2020. – Vol. 5. – Iss. 4. – P. 326–338. DOI: <https://doi.org/10.1016/j.ptlrs.2020.07.001>
14. Flowing bottomhole pressure prediction for gas wells based on support vector machine and random samples selection / W. Chen, Q. Di, F. Ye, J. Zhang, W. Wang // *International Journal of Hydrogen Energy*. – 2017. – Vol. 42. – P. 18333–18342. DOI: <https://doi.org/10.1016/j.ijhydene.2017.04.134>
15. Применение машинного обучения для прогнозирования пластового давления при разработке нефтяных месторождений / Д.А. Мартюшев, И.Н. Пономарева, Л.А. Захаров, Т.А. Шадров // *Известия Томского политехнического университета. Инжиниринг георесурсов*. – 2021. – Т. 332. – № 10. – С. 140–149. DOI: <https://doi.org/10.18799/24131830/2021/10/3401>
16. Чухлов А.С., Сальникова О.Л., Черных В.И. Оценка влияния геолого-физических характеристик залежей со сложным геологическим строением на условия притока углеводородов // *Недропользование*. – 2022. – Т. 22. – № 1. – С. 9–14.
17. Reproduction of reservoir pressure by machine learning methods and study of its influence on the cracks formation process in hydraulic fracturing / E.V. Filippov, L.A. Zakharov, D.A. Martyushev, I.N. Ponomareva // *Journal of Mining Institute*. – 2022. – Vol. 258. – P. 924–932. DOI: <https://doi.org/10.31897/PMI.2022.103>
18. Permeability prediction using logging data in a heterogeneous carbonate reservoir: A new self-adaptive predictor / P. Xu, H. Zhou, X. Liu et al. // *Geoenergy Science and Engineering*. – 2023. – Vol. 224. – Article 211635. DOI: <https://doi.org/10.1016/j.geoen.2023.211635>
19. Prediction of permeability of highly heterogeneous hydrocarbon reservoir from conventional petrophysical logs using optimized data-driven algorithms / A. Sheykhinasab, A.A. Mohseni, A.B. Bahari et al. // *Journal of Petroleum Exploration and Production Technology*. – 2023. – Vol. 13. – P. 661–689. DOI: <https://doi.org/10.1007/s13202-022-01593-z>
20. Prediction of permeability from well logs using a new hybrid machine-learning algorithm / M. Matinkia, R. Hashami, M. Mehrad et al. // *Petroleum*. – 2023. – Vol. 9. – Iss. 1. – P. 108–123. DOI: <https://doi.org/10.1016/j.petlm.2022.03.003>
21. Porosity and permeability prediction using a transformer and periodic long short-term network / L. Yang, S. Fomel, S. Wang et al. // *Geophysics*. – 2023. – Vol. 88. – Iss. 1. – P. IJF–Y3. DOI: <https://doi.org/10.1190/geo2022-0150.1>
22. Stanton-Yonge A., Mitchell T.M., Meredith P.G. The hydro-mechanical properties of fracture intersections: pressure-dependent permeability and effective stress law // *Journal of Geophysical Research: Solid Earth*. – 2023. – Vol. 128. – Iss. 2. – Article e2022JB025516. DOI: <https://doi.org/10.1029/2022JB025516>
23. Bhattacharjee S., Minzoni M., Prather B.E. Investigating the controls on architecture and facies distribution of a carbonate ramp to shelf system: Insights from stratigraphic forward modeling of the Jurassic Smackover Formation, Gulf of Mexico // *Marine and Petroleum Geology*. – 2024. – Vol. 160. – Article 106622. DOI: <https://doi.org/10.1016/j.marpetgeo.2023.106622>
24. Impact of effective stress on permeability for carbonate fractured-vuggy rocks / K. Sun, H. Liu, J.Y. Leung et al. // *Journal of Rock Mechanics and Geotechnical Engineering*. – 2023. DOI: <https://doi.org/10.1016/j.jrmge.2023.04.007>
25. Interporosity flow between matrix and fractures in carbonates: a study of its impact on oil production / D.A. Martyushev, I.N. Ponomareva, S. Davoodi, A. Kadhodaie // *Arabian Journal for Science and Engineering*. – 2024. DOI: <https://doi.org/10.1007/s13369-024-09533-1>
26. Прогнозирование проницаемости призабойной зоны пласта при волновом воздействии / Ч. Ци, М.А. Гузев, В.В. Поплыгин, А.А. Куницких // *Записки Горного института*. – 2022. – Т. 258. – С. 998–1007. DOI: <https://doi.org/10.31897/PMI.2022.59>
27. Дорфман М.Б., Сентемов А.А. Влияние фильтрационно-емкостных свойств призабойной зоны пласта на эффективность кислотной обработки // *Известия Томского политехнического университета. Инжиниринг георесурсов*. – 2020. – Т. 331. – № 2. – С. 124–130. DOI: <https://doi.org/10.18799/24131830/2020/2/2488>

28. Вирстюк А.Ю., Микшина В.С. Применение регрессионного анализа для оценки эффективности работы нефтяных скважин с парафинистой нефтью // Известия Томского политехнического университета. Инжиниринг георесурсов. – 2020. – Т. 331. – № 1. – С. 117–124. DOI: <https://doi.org/10.18799/24131830/2020/1/2453>
29. Глушаков А.А., Архипов А.И., Афанаскин И.В. Модель взаимодействия скважин при заводнении слоисто-неоднородного нефтяного пласта в рамках концепции CRM-моделирования // Георесурсы. – 2024. – Vol. 26 (3). – P. 162–174. DOI: <https://doi.org/10.18599/grs.2024.3.17>
30. Chaves G.S., Ferreira Filho V.J.M. Enhancing production monitoring: A back allocation methodology to estimate well flow rates and assist well test scheduling // Petroleum Research. – 2024. – Vol. 9 (3). – P. 369–379. DOI: <https://doi.org/10.1016/j.ptlrs.2024.03.008>
31. Rongbo S., Hua W., Lizhi X. Reservoir evaluation using petrophysics informed machine learning: A case study // Artificial Intelligence in Geosciences. – 2024. – Vol. 5. – Article 100070. DOI: <https://doi.org/10.1016/j.aiig.2024.100070>
32. Classification of reservoir quality using unsupervised machine learning and cluster analysis: Example from Kadanwari gas field, SE Pakistan / A. Nafees, C. Jian, F. Xiaodong, et al. // Geosystems and Geoenvironment. – 2023. – Vol. 2 (1). – Article 100123. DOI: <https://doi.org/10.1016/j.geogeo.2022.100123>

Информация об авторах

Андрей Витальевич Соромотин, инженер 1-й категории отдела проектирования, мониторинга и нейросетевой оптимизации разработки Северной группы месторождений ООО «ЛУКОЙЛ-Инжиниринг», Россия, 614015, г. Пермь, ул. Пермская, 3а. s@soromotinav.ru; <https://orcid.org/0000-0002-6535-6134>

Дмитрий Александрович Мартюшев, доктор технических наук, профессор кафедры нефтегазовых технологий Пермского национального исследовательского политехнического университета, Россия, 614990, г. Пермь, Комсомольский пр., 29. martyushevd@inbox.ru; <https://orcid.org/0000-0002-5745-4375>

Поступила в редакцию: 15.02.2024

Поступила после рецензирования: 02.05.2024

Принята к публикации: 11.11.2024

REFERENCES

1. Li Y., Kang Z., Xue Z., Zheng S. Theories and practices of carbonate reservoirs development in China. *Petroleum Exploration and Development*, 2018, vol. 45, Iss. 4, pp. 712–722. DOI: <https://doi.org/10.11698/PED.2018.04.12>
2. Zhang F., An M., Yan B., Wang Y., Han Y. A novel hydromechanical coupled analysis for the fractured vuggy carbonate reservoir. *Computers and Geotechnics*, 2019, vol. 106, pp. 68–82. DOI: <https://doi.org/10.1016/j.compgeo.2018.10.013>
3. Chen Y., Zhao J.-H., Hu Q.-H. Origin of carbonate minerals and impacts on reservoir quality of the Wufeng and Longmaxi Shale, Sichuan Basin. *Petroleum Science*, 2023, vol. 20, Iss. 6, pp. 3311–3336. DOI: <https://doi.org/10.1016/j.petsci.2023.08.012>
4. Li Y., Zhang Q., Wang D., Song B., Liu P. A fast method of waterflooding performance forecast for largescale thick carbonate reservoir. *Journal of Petroleum Science and Engineering*, 2020, vol. 192, Article 107227. DOI: <https://doi.org/10.1016/j.petrol.2020.107227>
5. Kaminskaite I., Fisher Q.J., Michie E.A. Microstructure and petrophysical properties of deformation bands in high porosity carbonates. *Journal of Structural Geology*, 2019, vol. 119, pp. 61–80. DOI: <https://doi.org/10.1016/j.jsg.2018.12.001>
6. Shedid A. Shedid. Vertical-horizontal permeability correlations using coring data. *Egyptian Journal of Petroleum*, 2019, vol. 28, pp. 97–101. DOI: <https://doi.org/10.1016/j.ejpe.2018.12.007>
7. Aljuboori F.A., Lee J.H., Elraies K.A., Stephen K.D. The effectiveness of flow salinity waterflooding in naturally fractured reservoirs. *Journal of Petroleum Science and Engineering*, 2020, vol. 191, Article 107167. DOI: <https://doi.org/10.1016/j.petrol.2020.107167>
8. Cordero J.A.R., Sanchez E.C.M., Roehl D. Integrated discrete fracture and dual porosity – dual permeability models for fluid flow in deformable fractured media. *Journal of Petroleum Science and Engineering*, 2019, vol. 175, pp. 644–653. DOI: <https://doi.org/10.1016/j.petrol.2018.12.053>
9. Özkaya S.I. Fracture modeling from borehole image logs and water invasion in carbonate reservoirs with layer-bound fractures and fracture corridors. *Journal of Petroleum Science and Engineering*, 2019, vol. 179, pp. 199–209. DOI: <https://doi.org/10.1016/j.petrol.2019.04.052>
10. Belhouchet H.E., Benzagouta M.S., Dobbai A., Alquraishi A., Duplay J. A new empirical model for enhancing well log permeability prediction, using nonlinear regression method: case study from Hassi-Berkine oil field reservoir – Algeria. *Journal of King Saud University – Engineering Sciences*, 2021, vol. 33, pp. 136–145. DOI: <https://doi.org/10.1016/j.jksues.2020.04.008>
11. Kaleem, W., Tewari, S., Fogat, M., Martyushev, D.A. Machine Learning Approach Based Study of Production Forecasting and Factors Influencing the Multiphase Flow through Surface Chokes. *Petroleum*, 2024, vol. 10, Iss. 2, pp. 354–371. DOI: <https://doi.org/10.1016/j.petlm.2023.06.001>

12. Guo Y., Liang Y., Li J., Gong B. A novel connectivity-based hierarchical model for multi-scale fracture system in carbonate reservoir simulation. *Fuel*, 2019, vol. 250, pp. 327–338. DOI: <https://doi.org/10.1016/j.fuel.2019.03.048>
13. Hamada G., Joseph V. Developed correlations between sound wave velocity and porosity, permeability and mechanical properties of sandstone core samples. *Petroleum Research*, 2020, vol. 5, Iss. 4, pp. 326–338. DOI: <https://doi.org/10.1016/j.ptlrs.2020.07.001>
14. Chen W., Di Q., Ye F., Zhang J., Wang W. Flowing bottomhole pressure prediction for gas wells based on support vector machine and random samples selection. *International Journal of Hydrogen Energy*, 2017, vol. 42, pp. 18333–18342. DOI: <https://doi.org/10.1016/j.ijhydene.2017.04.134>
15. Martyshev D.A., Ponomareva I.N., Zakharov L.A., Shadrov T.A. Application of machine learning for forecasting formation pressure in oil field development. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*, 2021, vol. 332, Iss. 10, pp. 140–149. DOI: <https://doi.org/10.18799/24131830/2021/10/3401>
16. Chuhlov A.S., Salnikova O.L., Chernyh V.I. Influence evaluation of geological and physical characteristics of reservoirs with a complex geological structure on the conditions of hydrocarbons inflow. *Perm Journal of Petroleum and Mining Engineering*, 2022, vol. 22, no. 1, pp. 9–14. (In Russ.)
17. Filippov E.V., Zakharov L.A., Martyshev D.A., Ponomareva I.N. Reproduction of reservoir pressure by machine learning methods and study of its influence on the cracks formation process in hydraulic fracturing. *Journal of Mining Institute*, 2022, vol. 258, pp. 924–932. DOI: <https://doi.org/10.31897/PMI.2022.103>
18. Xu P., Zhou H., Liu X. Permeability prediction using logging data in a heterogeneous carbonate reservoir: A new self-adaptive predictor. *Geoenergy Science and Engineering*, 2023, vol. 224, Article 211635. DOI: <https://doi.org/10.1016/j.geoen.2023.211635>
19. Sheykhinasab A., Mohseni A.A., Bahari A.B. Prediction of permeability of highly heterogeneous hydrocarbon reservoir from conventional petrophysical logs using optimized data-driven algorithms. *Journal of Petroleum Exploration and Production Technology*, 2023, vol. 13, pp. 661–689. DOI: <https://doi.org/10.1007/s13202-022-01593-z>
20. Matinkia M., Hashami R., Mehrad M. Prediction of permeability from well logs using a new hybrid machine-learning algorithm. *Petroleum*, 2023, vol. 9, Iss. 1, pp. 108–123. DOI: <https://doi.org/10.1016/j.petlm.2022.03.003>
21. Yang L., Fomel S., Wang S. Porosity and permeability prediction using a transformer and periodic long short-term network. *Geophysics*, 2023, vol. 88, pp. IJF–Y3. DOI: <https://doi.org/10.1190/geo2022-0150.1>
22. Stanton-Yonge A., Mitchell T.M., Meredith P.G. The hydro-mechanical properties of fracture intersections: pressure-dependent permeability and effective stress law. *Journal of Geophysical Research: Solid Earth*, 2023, vol. 128, Iss. 2, Article e2022JB025516. DOI: <https://doi.org/10.1029/2022JB025516>
23. Bhattacharjee S., Minzoni M., Prather B.E. Investigating the controls on architecture and facies distribution of a carbonate ramp to shelf system: insights from stratigraphic forward modeling of the Jurassic Smackover Formation, Gulf of Mexico. *Marine and Petroleum Geology*, 2024, vol. 160, Article 106622. DOI: <https://doi.org/10.1016/j.marpetgeo.2023.106622>
24. Sun K., Liu H., Leung J.Y. Impact of effective stress on permeability for carbonate fractured-vuggy rocks. *Journal of Rock Mechanics and Geotechnical Engineering*, 2023. DOI: <https://doi.org/10.1016/j.jrmge.2023.04.007>
25. Martyshev D.A., Ponomareva I.N., Davoodi S., Kadkhodaie A. Interporosity flow between matrix and fractures in carbonates: a study of its impact on oil production. *Arabian Journal for Science and Engineering*, 2024. DOI: <https://doi.org/10.1007/s13369-024-09533-1>
26. Qi Chengzhi, Guzev M.A., Poplygin V.V., Kunitskih A.A. Predicting the permeability of the near-bottomhole zone during wave impact. *Journal of Mining Institute*, 2022, vol. 258, pp. 998–1007. (In Russ.) DOI: <https://doi.org/10.31897/PMI.2022.59>
27. Dorfman M.B., Sentemov A.A. Influence of reservoir properties of the bottomhole zone on acidizing efficiency. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*, 2020, vol. 331, no. 2, pp. 124–130. (In Russ.) DOI: <https://doi.org/10.18799/24131830/2020/2/2488>
28. Virstyuk A.Yu., Mikshina V.S. Application of regression analysis to evaluate the efficiency of oil well operating with the paraffin oil. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*, 2020, vol. 331, no 1, pp. 117–124. (In Russ.) DOI: <https://doi.org/10.18799/24131830/2020/1/2453>
29. Glushakov A.A., Arhipov A.I., Aafanaskin I.V. Model of well interference during waterflooding of a layered heterogeneous oil reservoir within the framework of the CRM modeling concept. *Georesursy*, 2024, vol. 26, no 3, pp. 162–174. (In Russ.) DOI: <https://doi.org/10.18599/grs.2024.3.17>
30. Chaves G.S., Ferreira Filho V.J.M. Enhancing production monitoring: A back allocation methodology to estimate well flow rates and assist well test scheduling. *Petroleum Research*, 2024, vol. 9, Iss. 3, pp. 369–379. DOI: <https://doi.org/10.1016/j.ptlrs.2024.03.008>
31. Rongbo S., Hua W., Lizhi X. Reservoir evaluation using petrophysics informed machine learning: A case study. *Artificial Intelligence in Geosciences*, 2024, vol. 5, Article 100070. DOI: <https://doi.org/10.1016/j.aiig.2024.100070>
32. Nafees A., Jian C., Xiaodong F. Classification of reservoir quality using unsupervised machine learning and cluster analysis: Example from Kadanwari gas field, SE Pakistan. *Geosystems and Geoenvironment*, 2023, vol. 2, Iss. 1, Article 100123. DOI: <https://doi.org/10.1016/j.geogeo.2022.100123>

Information about the authors

Andrey V. Soromotin, 1st category engineer, LLC “LUKOIL-Engineering”, 3a, Permskaya street, Perm, 614015, Russian Federation. s@soromotinav.ru; <https://orcid.org/0000-0002-6535-6134>

Dmitriy A. Martyushev, Dr. Sc., Professor, Perm National Research Polytechnic University, 29, Komsomolsky avenue, Perm, 614990, Russian Federation. martyushevd@inbox.ru, <https://orcid.org/0000-0002-5745-4375>

Received: 15.02.2024

Revised: 02.05.2024

Accepted: 11.11.2024