

УДК 519.6
МРНТИ 28.23

DOI: <https://doi.org/10.54859/kjogi108649>

Получена: 03.05.2023.

Одобрена: 21.08.2023.

Опубликована: 30.09.2023.

Оригинальное исследование

Исследование эффективности алгоритмов машинного обучения на основе данных различных горных пород

Б.К. Асилбеков^{1,2}, Н.Е. Калжанов^{2,3}, Д.А. Болысбек^{1,3}, К.Ш. Узбекалиев¹,
Б.Е. Бекбау¹, А.Б. Кульджабеков^{1,2}

¹Satbayev University, г. Алматы, Казахстан

²KBTU BIGSoft, г. Алматы, Казахстан

³Казахский национальный университет имени аль-Фараби, г. Алматы, Казахстан

АННОТАЦИЯ

Обоснование. Абсолютная проницаемость играет важную роль в изучении течения жидкостей в пористых средах при разработке нефтегазовых месторождений, закачке CO₂ в пласты для хранения, мониторинге миграции загрязнителей в подземных водоносных слоях, а также моделировании каталитических систем. Следовательно, точная и оперативная оценка её значений является актуальной задачей.

Цель. Целью настоящей статьи является изучение применимости методов машинного обучения для прогнозирования абсолютной проницаемости карбонатных образцов, а также путей улучшения прогноза проницаемости.

Материалы и методы. В качестве входных используются данные 408 мини-объемов, отобранные из четырех цилиндрических карбонатных образцов, практически полностью состоящих из кальцита. Входные данные включают общую и связанную пористости, удельную площадь поверхности, радиусы всех пор, а также радиусы только соединенных между собой пор, координационные числа, радиусы и длины горловины пор, извилистость и абсолютную проницаемость. Оценка проницаемости осуществляется с помощью регрессионных методов машинного обучения, таких как метод случайного леса, чрезвычайно случайных деревьев и модифицированный метод повышения градиента. Параметры (данные) мини-объемов были определены при помощи поромасштабного моделирования течения воды в их поровом пространстве с применением специализированного программного пакета Avizo.

Результаты. Были проанализированы данные мини-объемов, отобранные из трещиноватого и нетрещиноватых образцов, и результаты показали, что имеются хорошие взаимосвязи между многими параметрами мини-объемов. Например, связанная и общая пористости имеют полиномиальную взаимосвязь второй степени с высоким коэффициентом корреляции. С помощью вышесказанных регрессионных методов машинного обучения были спрогнозированы значения абсолютной проницаемости при разделении входных данных на данные обучения и тестирования в соотношении 80/20 и 70/30.

Заключение. Использование логарифма проницаемости, а также отдельное рассмотрение трещиноватого и нетрещиноватых образцов позволили увеличить точность прогноза абсолютной проницаемости с применением вышеупомянутых методов машинного обучения до 90%. Метод чрезвычайно случайных деревьев является наиболее точным из трех рассмотренных методов машинного обучения для нашей задачи.

Ключевые слова: машинное обучение, Random Forest, XGBoost, Extra Trees, абсолютная проницаемость, карбонатная порода, рентгеновская микрокомпьютерная томография.

Как цитировать:

Асилбеков Б.К., Калжанов Н.Е., Болысбек Д.А., Узбекалиев К.Ш., Бекбау Б.Е., Кульджабеков А.Б. Исследование эффективности алгоритмов машинного обучения на основе данных различных горных пород // *Вестник нефтегазовой отрасли Казахстана*. 2023. Том 5, №3. С. 5–19. DOI: <https://doi.org/10.54859/kjogi108649>.

UDC 519.6
CSCSTI 28.23DOI: <https://doi.org/10.54859/kjogi108649>

Received: 03.05.2023.

Accepted: 21.08.2023.

Published: 30.09.2023.

Original article**Study of the efficiency of machine learning algorithms based on data of various rocks****Bakytzhan K. Assilbekov^{1,2}, Nurlykhan Ye. Kalzhanov^{2,3}, Darezhat A. Bolysbek^{1,3}, Kenboy Sh. Uzbekaliyev¹, Bakbergen Ye. Bekbau¹, Alibek B. Kuljabekov^{1,2}**¹*Satbayev University, Almaty, Kazakhstan*²*KBTU BIGSoft, Almaty, Kazakhstan*³*Al-Farabi Kazakh National University, Almaty, Kazakhstan***ANNOTATION**

Background: Absolute permeability plays an important role in studying the fluids flow in porous media during the development of oil and gas reservoirs, the injection of CO₂ into reservoirs for storage, the monitoring of pollutants migration in underground aquifers, and the modeling of catalytic systems. Therefore, an accurate and fast evaluation of its values is an important task.

Aim: The purpose of this article is to study the applicability of machine learning methods for predicting the absolute permeability of carbonate samples, as well as ways to improve the prediction of permeability.

Materials and methods: The input data is 408 small volumes extracted from four cylindrical carbonate samples composed almost entirely of calcite. Input data includes total and connected porosity, specific surface area, radii of all and only connected pores, coordination number, throat radius and length, tortuosity, and absolute permeability. Permeability prediction is carried out using regression machine learning methods such as random forest, extremely random trees and extended gradient boosting. Parameters (data) of small volumes were determined using pore-scale modeling of water flow in their pore space applying a specialized Avizo software.

Results: Data of small volumes extracted from fractured and non-fractured samples were analyzed, and the results showed that there are good relationships between many parameters of small volumes. For example, the connected and total porosity have a second-order polynomial relationship with a high correlation coefficient. Using the above-mentioned regression machine learning methods, absolute permeability values were predicted when input data divided into training and testing data in a ratio of 80/20 and 70/30.

Conclusion: Using the logarithm of permeability instead of permeability itself and considering fractured and non-fractured samples separately, can increase the accuracy of absolute permeability prediction using the above-mentioned machine learning methods up to 90%. The extremely random trees method is the most accurate among the three machine learning methods considered for our task.

Keywords: *machine learning, Random Forest, XGBoost, Extra Trees, absolute permeability, carbonate rocks, X-Ray microcomputed tomography.*

To cite this article:

Assilbekov BK, Kalzhanov NY, Bolysbek DA, Uzbekaliyev KS, Bekbau BY, Kuljabekov AB. Study of the efficiency of machine learning algorithms based on data of various rocks. *Kazakhstan journal for oil & gas industry.* 2023;5(3):5–19. DOI: <https://doi.org/10.54859/kjogi108649>.

ӨЖ 519.6
ГТАХР 28.23

DOI: <https://doi.org/10.54859/kjogi108649>

Қабылданды: 03.05.2023.

Мақұлданды: 21.08.2023.

Жарияланды: 30.09.2023.

Түпнұсқа зерттеу

Өртүрлі тау жынысының деректері негізінде машиналық оқу алгоритмдерінің тиімділігін зерттеу

Б.К. Асылбеков^{1,2}, Н.Е. Қалжанов^{2,3}, Д.Ө. Болысбек^{1,3}, К.Ш. Өзбекалиев¹,
Б.Е. Бекбау¹, А.Б. Кульджабеков^{1,2}

¹Satbayev University, Алматы қаласы, Қазақстан

²KBTU BIGSoft, Алматы қаласы, Қазақстан

³Әл-Фараби атындағы Қазақ Ұлттық Университеті, Алматы қаласы, Қазақстан

ТҮЙІНДЕМЕ

Негіздеу. Абсолютті өткізгіштік мұнай және газ кен орындарын игеруде, сақтау мақсатында CO₂ қабаттарға айдауда, жер асты суы қабаттарын ластаушы заттардың миграциясын бақылауда кеуекті орталардағы сұйықтардың ағысын және каталитикалық жүйелерді модельдеуде маңызды рөл атқарады. Сондықтан оның мөндерін дәл және тез анықтау маңызды мәселе болып табылады.

Мақсаты. Бұл мақаланың мақсаты – карбонат үлгілерінің абсолютті өткізгіштігін болжау үшін машиналық оқыту әдістерін қолдану мүмкіндігін, сондай-ақ өткізгіштікті болжауды жақсарту жолдарын зерттеу.

Материалдар мен әдістер. Кіріс деректері ретінде, толығымен дерлік кальциттен тұратын төрт цилиндрлік карбонат үлгілерден алынған 408 шағын-көлемдер қолданылды. Кіріс деректері жалпы және байланысқан кеуектілікті, беттің меншікті ауданын, барлық және тек байланысқан кеуектердің радиустарын, координация санын, кеуек мойнының радиусы мен ұзындығын, бұралуды және абсолютті өткізгіштікті қамтиды. Өткізгіштікті болжау кездейсоқ орман, өте кездейсоқ ағаштар және модификацияланған градиентті күшейту сияқты регрессиялық машиналық оқыту әдістерін қолдану арқылы жүзеге асырылады. Шағын көлемдердің параметрлері (деректері) арнаулы Avizo бағдарламалық пакетін пайдалана отырып, олардың кеуекті кеңістігіндегі су ағысын кеуек-масштапта модельдеу арқылы анықталды.

Нәтижелері. Сызатты және сызатсыз үлгілерден алынған шағын-көлемдердің деректері талданды және талдаулар шағын-көлемдердің көптеген параметрлері арасында жақсы байланыс бар екенін көрсетті. Мысалы, байланысқан және жалпы кеуектілік жоғары корреляция коэффициентімен екінші дәрежелі полиномдық байланысқа ие. Жоғарыда аталған регрессиялық машиналық оқытудың әдістерін қолдана отырып, кіріс деректерін оқыту және тестілеу деректеріне 80/20 және 70/30 қатынасында бөлу кезінде абсолютті өткізгіштік мөндері болжанды.

Қорытынды. Өткізгіштіктің орнына оның логарифмін қолдану, сонымен қатар сызатты және сызатсыз үлгілерді бөлек қарастыру арқылы, жоғарыда аталған машиналық оқыту әдістерін пайдалана отырып, абсолютті өткізгіштікті болжаудың дәлдігін 90%-ға дейін арттыруға болады. Өте кездейсоқ ағаштар әдісі біздің есеп үшін қарастырылған машиналық оқытудың үш әдісінің ішінде ең дәлі болып табылды.

Негізгі сөздер: *Машиналық оқыту, Random Forest, XGBoost, Extra Trees, абсолютті өткізгіштік, карбонатты тау жынысы, рентгендік микрокомпьютерлік томография.*

Дәйексөз келтіру үшін:

Асылбеков Б.Қ., Қалжанов Н.Е., Болысбек Д.Ө., Өзбекалиев К.Ш., Бекбау Б.Е., Құлжабеков Ә.Б. Өртүрлі тау жынысының деректері негізінде машиналық оқу алгоритмдерінің тиімділігін зерттеу // *Қазақстанның мұнай-газ саласының хабаршысы*. 2023. 5 том, №3, 5–19 б. DOI: <https://doi.org/10.54859/kjogi108649>.

Введение

Абсолютная проницаемость является важной макроколической характеристикой при течении жидкостей в поровом пространстве горных пород, и её определение является актуальной задачей, например, при оценке рациональности разработки нефтегазовых месторождений и эффективности закачки CO_2 в пласты, эффективности работ каталитических систем, загрязненности подземных вод и т.д. Обычно ищется зависимость между проницаемостью и другими характеристиками пористых материалов на основе множественных лабораторных измерений на керновых образцах, что занимает много времени и требует специального оборудования. Кроме этого, лабораторные условия позволяют осуществлять измерения проницаемости керновых материалов только в сантиметровом масштабе, что является грубоватой оценкой проницаемости, а течение жидкостей в пористых средах происходит в масштабе пор, и, следовательно, должны быть учтены более мелкие масштабы при оценке проницаемости пород.

Альтернативным способом определения проницаемости пород является расчёт по аналитическим формулам. Широко используемым является уравнение Козени-Кармана, которое связывает проницаемость k с пористостью ϕ , удельной площадью поверхности и извилистостью пористой среды [1, 2]. Однако уравнение Козени-Кармана даёт неправильные значения k для большинства реальных пористых материалов [2, 3]. В литературе также широко используются уравнения, описывающие связь между проницаемостью и общей пористостью $k \sim \phi^n$ [4–6], проницаемостью и связанной пористостью $k \sim \phi_{\text{св}}^n$ [7], проницаемостью и перколяционным порогом пористости $k \sim (\phi - \phi_c)^n$ (n – показатель степени) [7, 8]. Кроме этого, применяется уравнение, связывающее проницаемость с характерным размером пористой среды l : $k \sim \phi l^2$ [9, 10]. Однако вышеприведённые уравнения имеют как свои преимущества, так и недостатки, и их применимость ограничена такими факторами, как точность расчётов, сложная поровая структура горных пород и труднодоступность многих параметров (связанная пористость, перколяционный порог пористости, характерный размер среды).

За последнее десятилетие машинное обучение стало довольно популярным инструментом в классификации, регрессии и обработке изображений, которые встречаются в различных задачах. Прогнозирование проницаемости пористых сред осуществляется с применением регрессионных методов машинного обучения и методов глубокого

машинного обучения. Для прогнозирования проницаемости методы глубокого машинного обучения используют изображения горных пород как входные данные, полученные с помощью рентгеновской микрокомпьютерной томографии, и в качестве метода обучения применяются свёрточные нейронные сети [11, 12].

Регрессионные методы машинного обучения широко применяются при прогнозировании проницаемости пористой среды, т.к. они являются более удобными в реализации и не требуют изображений образцов в обучающих целях, что не всегда доступно. Эти методы также подходят для классификации типов пород по их петрофизическим характеристикам [13] и прогнозировании проницаемости пород по данным геофизического исследования скважин (далее – ГИС) [14, 15].

Egofeev и др. [16] применили несколько регрессионных методов машинного обучения для прогнозирования изменения пористости и проницаемости после удаления соли из 102 керновых материалов. Их результаты показали, что лучшими методами среди использованных оказались метод опорных векторов и нейронные сети. Они также отметили, что количество независимых признаков (входных параметров) заметно влияет на результаты прогнозирования пористости и проницаемости. Так, например, при использовании всего одного признака для прогнозирования пористости достоверность прогноза составила 69%, а в случае использования всех доступных признаков этот показатель составил 90%.

Tembely и др. [17] использовали регрессионные методы машинного обучения вместе с методами глубокого машинного обучения для прогнозирования абсолютной проницаемости пород на основе данных 1159 карбонатных образцов. В качестве входных признаков для построения моделей были использованы пористость, фактор образования и проницаемость, вычисленная с помощью поросетевого моделирования. Результаты показали, что лучшими методами оказались модифицированный метод повышения градиента (XGBoost) и глубокие нейронные сети, которые спрогнозировали проницаемости с достоверностью 90% и 92% соответственно.

Rezaee и Ekundayo [14] показали, что метод градиентного спуска (GBoost) и случайного леса (Random Forest) являются наиболее мощными во время теста и валидации, хотя GBoost показал наилучший результат при проведении слепого теста. Они использовали данные ГИС в качестве входных признаков в методы машинного

обучения, но авторы выбрали искусственные нейронные сети как самый лучший метод для прогнозирования проницаемости пород, т.к. он даёт практически одинаковые результаты при различных количествах признаков и является самым быстрым.

Mohammadian и др. [13] изучили влияние классификации пород по их типу на результаты прогнозирования абсолютной проницаемости с помощью XGBoost. Они показали, что, если произвести классификацию пород по их индексу зоны течения (FZI), можно достичь высокой точности прогнозирования проницаемости пород. Авторы получили проницаемости с помощью метода машинного обучения с 97%-й точностью по данным 128 образцов кернов, для которых диапазон изменения проницаемости составил 0,11–122,7 мД.

В настоящей статье изучаются пути улучшения прогноза абсолютной проницаемости методами машинного обучения. Разделение данных по признаку трещиноватости и использование логарифма проницаемости вместо самой проницаемости привело к заметному улучшению результатов прогноза проницаемости.

Материалы и методы

Обучение и тестирование методов машинного обучения проводились по данным 408 мини-объемов (объемом около 512 мм³), которые были отобраны из 4 карбонатных цилиндрических образцов до и после закачки в них растворов соляной кислоты. На рис. 1 (а) показаны трехмерные цифровые модели цилиндрических образцов №2, 7, 10 и 13, которые были испытаны во время проведенных нами экспериментов по закачке кислотных растворов [18]. Темно-синими областями на светло-синем фоне выделены каналы растворения. Диаметр и длина образцов составили около 3 и 5 см соответственно. Результаты рентгеновской дифрактометрии показали, что все образцы практически полностью состоят из кальцита, содержание кварца составляет менее 1%. Краткая информация по кислотным растворам и образцам до и после закачки, приведена в табл. 1. Трехмерные цифровые модели образцов до и после закачки кислотных растворов были построены с помощью программного пакета Avizo на основе их томографических изображений.

Процесс отбора кубических мини-объемов из цилиндрических образцов схематически проиллюстрирован на рис. 1 (б), где красный квадрат обозначает место отбора. Идентичность мини-образцов из цифровой модели одного и того же образца до и после закачки кислотного

раствора была максимально обеспечена. Поровые пространства отобранных мини-объемов, которые далее использовались для построения поровой сети, показаны синим на рис. 1 (б). Отметим, что образец №2 имеет явно выраженные трещины, направление которых показаны красной линией на рис. 1 (в). С целью отображения трещин показаны изображения только разного сечения образца, где Z показывает их расстояние от входного сечения. Также отметим, что основной целью отбора мини-объемов являлось увеличение количества пористых сред для формирования входного слоя в методы машинного обучения.

После того как были отобраны мини-объемы, были извлечены их поровые сети (рис. 1, в). Затем была проведена симуляция течения воды на поровых сетях мини-объемов с помощью подходов поромасштабного моделирования с целью расчёта их микроскопических и макроскопических характеристик (табл. 2). Поромасштабное моделирование было проведено с помощью программного пакета Avizo.

В качестве методов машинного обучения были выбраны метод случайного леса (Random Forest), модифицированный метод повышения градиента (XGBoost) и чрезвычайно случайных деревьев (Extra Trees). Все характеристики мини-образцов, кроме проницаемости, были использованы в качестве входных данных методов машинного обучения, а проницаемость являлась целевой переменной, которую нужно прогнозировать. Отметим, что управляемые параметры всех рассмотренных методов машинного обучения были использованы по умолчанию. Метод Random Forest основан на использовании множеств независимых друг от друга деревьев решений, в котором окончательное значение прогнозируемой величины получается осреднением прогнозов по всем деревьям решения [16]. Метод XGBoost является более упорядоченной формой обычного метода повышения градиента и использует расширенную регуляризацию, которая улучшает возможности обобщения модели. XGBoost обеспечивает более высокую производительность по сравнению с обычным методом повышения градиента [19]. Метод Extra Trees является методом, основанным на алгоритме оптимизации обучения методом наименьших квадратов [20]. Методы Extra Trees и Random Forest создают множество деревьев решений, но выборка для каждого дерева является случайной, без замены. Это создаёт набор данных для каждого дерева с уникальными образцами.

Таблица 1. Краткая информация по кислотным растворам и образцам до и после закачки
Table 1. Summary of acid solutions and samples before and after injection

№ образца Sample number	Пористость до закачки, % Porosity (before injection), %	Концентрация HCl в растворе, % HCl concentration in solution, %	Скорость закачки, мл/мин Injection rate, ml/min	Проницаемость до закачки, μm^2 Permeability (before injection), μm^2	Проницаемость после закачки, μm^2 Permeability (after injection), μm^2
2	20,6	18	8	0,43	3,79
7	20,9	12	8	0,71	3,85
10	19,0	18	2	0,29	0,98
13	20,0	12	4	0,45	4,1

Таблица 2. Наименование рассчитанных характеристик мини-объемов
Table 2. Name of the computed characteristics of small volumes

Удельная площадь поверхности (S), μm^{-1} Specific surface area (S), μm^{-1}	Связанная пористость (ϕ_c) Connected porosity (ϕ_c)	Общая пористость (ϕ_t) Total porosity (ϕ_t)	Радиус всех пор (r_p), μm Radius of all pores (r_p), μm	Извилистость (τ) Tortuosity (τ)
Координационное число (N_c) Coordination number (N_c)	Радиус горловины (r_t), μm Throat radius (r_t), μm	Длина горловины (l_t), μm Throat length (l_t), μm	Радиус связанных пор (r_{pc}), μm Radius of connected pores (r_{pc}), μm	Проницаемость (k), μm^2 Permeability (k), μm^2

Результаты и их обсуждения

Прогноз проницаемости методами машинного обучения

Прежде чем прогнозировать проницаемость, был проведен анализ исходных данных. На рис. 2 (а) показана визуализация исходных данных в виде попарных зависимостей между каждым признаками и диаграммы распределения каждого признака. Как видно на рисунке, имеется четкая взаимосвязь между всеми признаками, за исключением взаимосвязи между извилистостью и остальными признаками. Извилистость остаётся практически постоянной. Отметим, что проницаемость меняется в очень широком диапазоне (0,0002–893 μm^2) со средним значением в 6,3 μm^2 , следовательно, распределение проницаемости проиллюстрировано не лучшим образом. В связи с этим далее в статье рассмотрен логарифм от проницаемости вместо самой проницаемости в целях улучшения не только её распределения, но и прогноза её значений.

На рис. 2 (а) видна чёткая взаимосвязь между связанной и общей пористостями, которая подтверждается высоким коэффициентом корреляции (0,99) (рис. 2, б). Общая пористость образца породы может быть высокой, но, как известно, течение жидкостей в поровом пространстве в основном характеризуется связанной пористостью, т.е. пористостью соединенных между собой пор образца. В среднем для большинства горных пород связанная пористость составляет приблизительно 85–95% общей порис-

тости. В нашем случае этот показатель составляет 86%.

Взаимосвязь между связанной и общей пористостями позволяет определить так называемый перколяционный порог пористости ϕ_p , ниже которого поровое пространство образца считается непроницаемым, т.е. проницаемость превращается в ноль [7]. Знание перколяционного порога пористости позволяет оценить вместительные и транспортные свойства пород, например, для закачки воды или газа с целью вытеснения нефти из пластов или перед закачкой CO_2 в пласты для дальнейшего его хранения. В настоящем исследовании ϕ_p был определен как положительный корень квадратного уравнения $\phi_c = -1,48\phi_t^2 + 1,71\phi_t - 0,09$, которое описывает взаимосвязь между связанной и общей пористостями, и составил $\approx 5\%$.

Из рис. 2 (а) также заметим, что удельная площадь поверхности S имеет корреляцию со многими признаками. Особенно важной является взаимосвязь между S и пористостью с коэффициентом корреляции -0,49 (рис. 2, б). Корonen et al. [7] описывали взаимосвязь между S и пористостью уравнением $S = -2\phi_t \ln \phi / 18,6$. В нашем случае данная связь описывалась линейным уравнением $S = -0,061\phi_t + 0,036$ с коэффициентом корреляции 0,24. Раздельное рассмотрение трещиноватого и нетрещиноватых образцов привело к уравнениям $S = -0,099\phi_t + 0,037$ и $S = -0,077\phi_t + 0,041$ с коэффициентами корреляции 0,72 и 0,61 соответственно.

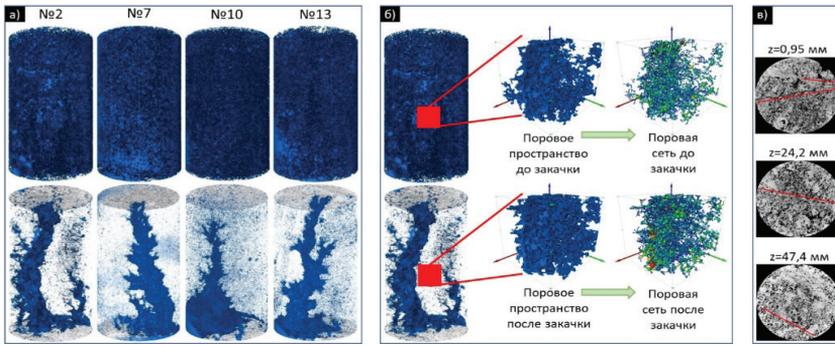


Рисунок 1. 3D цифровые модели образцов (а), отбор мини-объемов (б) и отображение имеющихся трещин в образце №2 (в)
Figure 1. 3D digital models of samples (a), extraction of small volumes (b) and display of existing fractures in sample #2 (c)

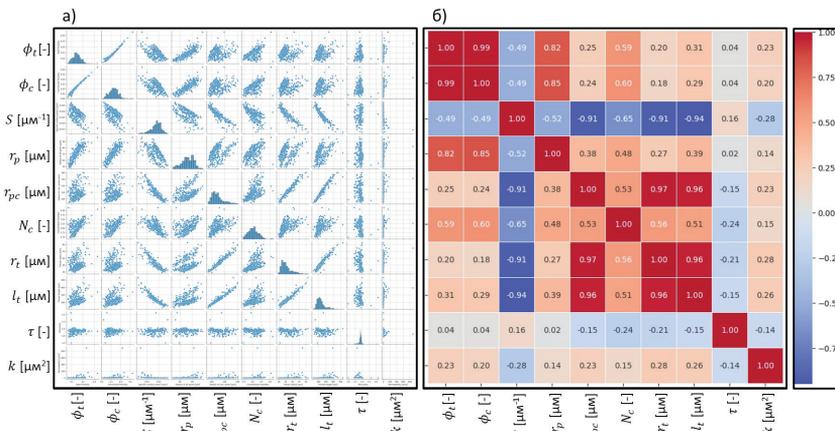


Рисунок 2. Парные зависимости (а) и корреляционная матрица (б) исходных данных
Figure 2. Pairwise (a) and correlation matrix (b) for the initial data

Рис. 2 (а) раскрывает линейную взаимосвязь между радиусом и длиной горловины пор с высоким коэффициентом корреляции 0,96 (рис. 2, б). Это означает, что вместе с ростом радиуса горловины длина горловины также растёт, например, во время растворения породы при закачке кислотных составов в образцы, что указывает на объединение/укрупнение пор.

На рис. 2 (б) показаны коэффициенты корреляции между признаками, где красный цвет указывает на прямые корреляции, а синий – на обратные. Как видно, удельная площадь поверхности имеет обратные связи с остальными признаками, за исключением извилистости. Как показывает рис. 2 (б), целевая переменная (проницаемость) имеет низкие коэффициенты корреляции с входными признаками, т.к. проницаемость имеет нелинейный характер при изменении входных признаков. Рис. 2 (б) указывает на очень

важный фактор – исключение тех входных признаков, которые имеют очень высокие коэффициенты корреляции с остальными входными признаками из общего количества признаков. Например, можно исключить либо общую пористость, либо связанную пористость, т.к. они имеют чёткую взаимосвязь между собой. Благодаря лёгкому, по сравнению со связанной пористостью, определению общей пористости, очевидно, что нужно оставить общую пористость в общем количестве входных признаков. Уменьшение количества входных признаков позволяет снизить время обучения и прогноза.

На рис. 3 показаны прогнозируемая и истинная проницаемости мини-объемов при разделении входных данных в соотношении 70/30 (рис. 3, а) и 80/20 (рис. 3, б).

Как видно на рис. 3, все рассмотренные методы машинного обучения прогнозировали проницаемость с низкими коэффициентами

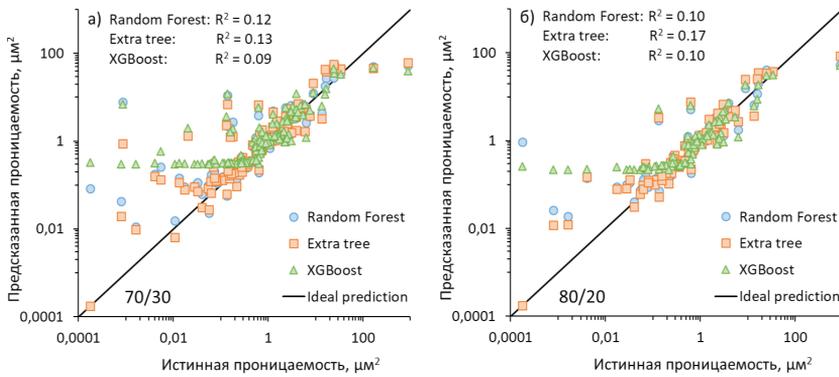


Рисунок 3. Прогнозная и истинная проницаемости при разделении данных в соотношении 70/30 (а) и 80/20 (б)

Figure 3. Predicted and true permeability for data division in the ratio of 70/30 (a) and 80/20 (b)

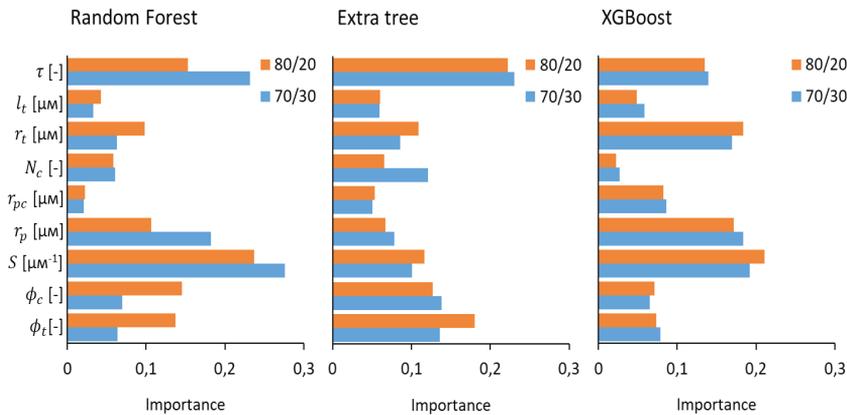


Рисунок 4. Значимость входных признаков при прогнозировании проницаемости методами Random Forest (слева), Extra Tree (в центре) и XGBoost (справа)

Figure 4. Feature importances in permeability prediction using Random Forest (left), Extra Tree (center), and XGBoost (right) methods

достоверности при обоих соотношениях разделения входных данных. Низкие значения проницаемости были переоценены, указывая на то, что распределение проницаемости имеет нелинейный характер при низких значениях пористости.

Наоборот, высокие значения проницаемости ($>1 \mu\text{m}^2$), полученные с помощью методов машинного обучения, близко находятся к истинным значениям проницаемости. Плохая прогнозирующая способность рассмотренных методов машинного обучения низких проницаемостей также может быть связана с присутствием данных минимальных объемов, отобранных из трещиноватого образца. Далее используется логарифм проницаемости вместо самой проницаемости и отдельно рассматривается трещиноватый образец с целью улучшения прогнозирующей способности методов машинного обучения при низких значениях проницаемости.

Значимость входных признаков при прогнозировании проницаемости методами Random Forest, Extra Tree и XGBoost показана на рис. 4. Как видно на рисунке, Random Forest и XGBoost считали извилистость и удельную площадь поверхности наиболее важными при прогнозировании, тогда как Extra Tree выбрал наиболее важными извилистость и пористость. Отметим, что эти параметры являются основными составляющими факторами в уравнении Козени-Кармана.

Использование логарифма проницаемости

Здесь и далее будем использовать (натуральный) логарифм проницаемости вместо самой проницаемости. Логарифмическая функция резко меняется в интервале (0; 1], и это позволяет считать низкие значения проницаемости наиболее сопоставимыми с ее высокими значениями в логарифмической шкале.

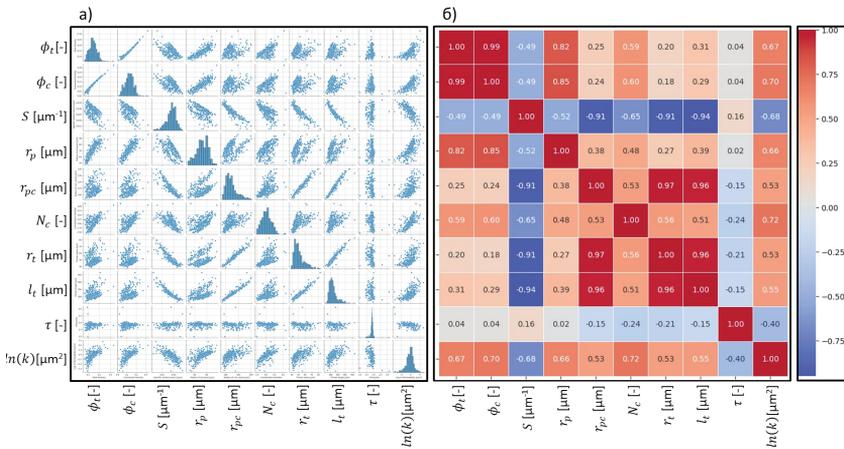


Рисунок 5. Парные зависимости (а) и корреляционная матрица (б) исходных данных
 Figure 5. Pairwise (a) and correlation matrix (b) for the initial data

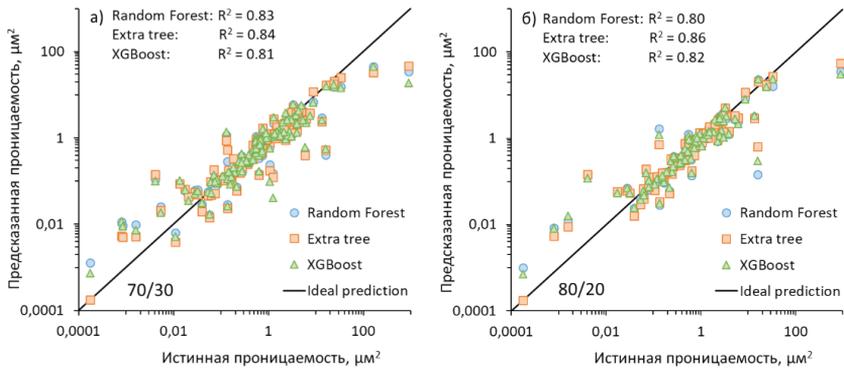


Рисунок 6. Прогнозная и истинная проницаемости при разделении данных в соотношении 70/30 (а) и 80/20 (б)
 Figure 6. Predicted and true permeability for data division in the ratio of 70/30 (a) and 80/20 (b)

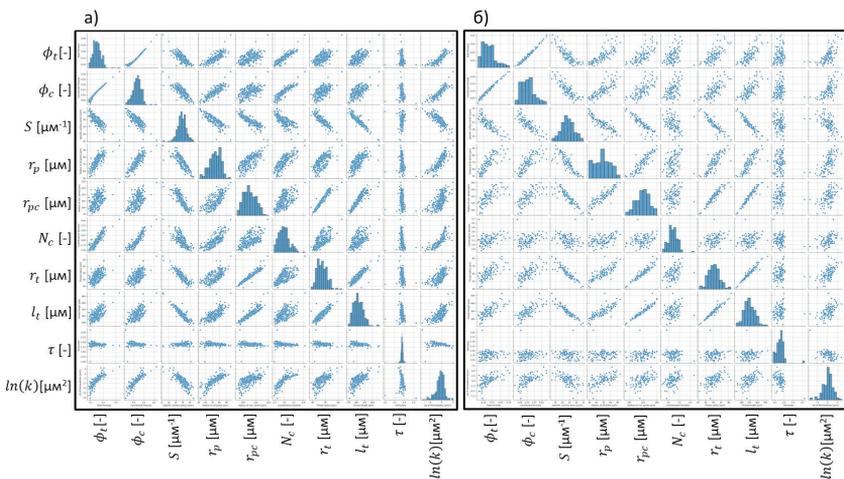


Рисунок 7. Парные зависимости и диаграммы распределения данных мини-объемов, отобранные из нетрещиноватых (а) и трещиноватых (б) образцов
 Figure 7. Pair-plots and distribution diagrams of small volumes, extracted from non-fractured (a) and fractured (b) samples

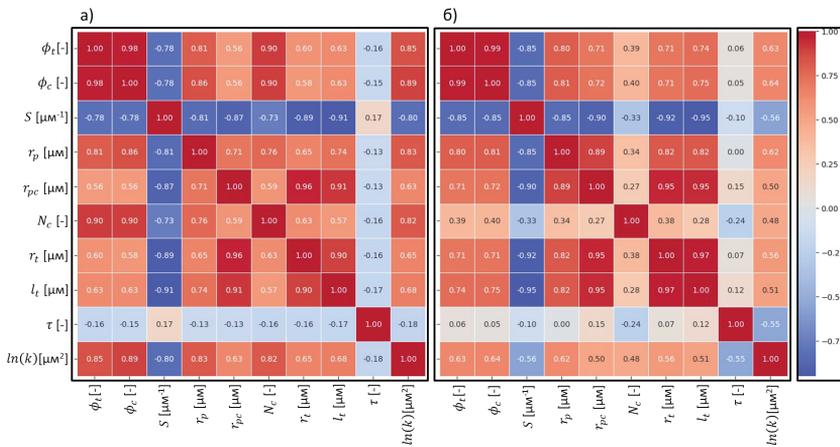


Рисунок 8. Корреляционная матрица между исходными данными мини-объемов, отобранными из нетрещиноватых (а) и трещиноватых (б) образцов
Figure 8. Correlation matrix for the initial data of small volumes, extracted from non-fractured (a) and fractured (b) samples

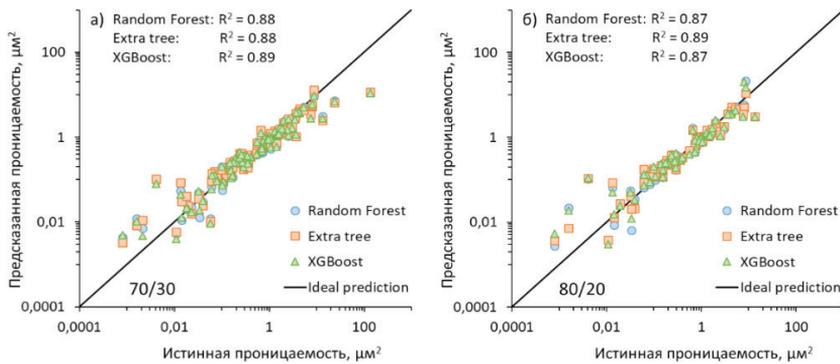


Рисунок 9. Прогнозная и истинная проницаемости мини-объемов, отобранные из нетрещиноватых образцов, при разделении данных в соотношении 70/30 (а) и 80/20 (б)
Figure 9. Predicted and true permeabilities of small volumes extracted from non-fractured samples for the data division in a ratio of 70/30 (a) and 80/20 (b)

Повторное прогнозирование проницаемости показало, что взаимосвязи между логарифмом проницаемости и входными признаками явно выражены (рис. 5–6) по сравнению со случаем, когда использовалась абсолютная проницаемость (рис. 2, а). Рис. 5 (б) показывает, что коэффициенты корреляции между логарифмом проницаемости и входными признаками существенно увеличились. Например, если коэффициенты корреляции проницаемости с общей пористостью и удельной площадью поверхности составили 0,23 и -0,28 (рис. 2, б) соответственно, то в случае использования логарифма проницаемости эти коэффициенты соответственно выросли до 0,67 и -0,68 (рис. 5, б). Это означает, что логарифм проницаемости имеет лучшую корреляцию с входными признаками, чем просто проницаемость. Причиной этому может

быть то, что в общем случае связь между проницаемостью и другими параметрами пористой среды является нелинейной (степенной закон).

Как показывает рис. 6, все три рассмотренных метода машинного обучения показали лучшие результаты по сравнению со случаем использования самой проницаемости в качестве целевой переменной. Коэффициенты достоверности прогноза этими методами превысили 80% (рис. 6), тогда как эти коэффициенты имели значения чуть больше 10% в случае использования самой проницаемости (рис. 3). Основной причиной улучшения было адекватное прогнозирование низких проницаемостей, которые стали гораздо ближе к истинным значениям проницаемости. Отметим, что сначала был прогнозирован логарифм проницаемости, после чего обратно

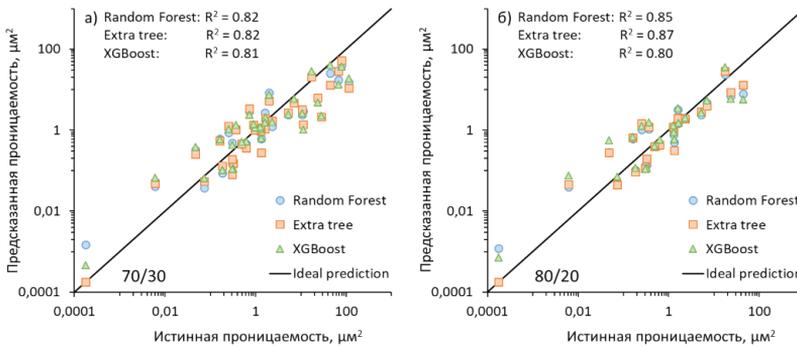


Рисунок 10. Прогнозная и истинная проницаемости мини-объемов, отобранные из трещиноватого образца, при разделении данных в соотношении 70/30 (а) и 80/20 (б)
Figure 10. Predicted and true permeabilities of small volumes extracted from a fractured sample for the data division in a ratio of 70/30 (a) and 80/20 (b)

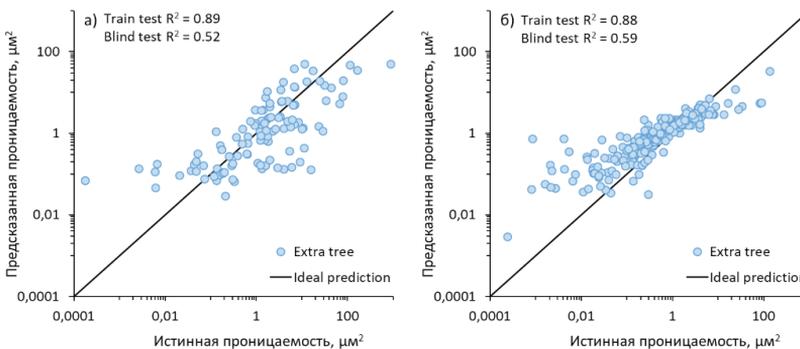


Рисунок 11. Прогнозная и истинная проницаемости мини-объемов, отобранные из трещиноватого (а) и нетрещиноватых (б) образцов, во время слепых тестов
Figure 11. Predicted and true permeabilities of small volumes extracted from (a) fractured and (b) non-fractured samples during blind tests

преобразовали его к самой проницаемости, чтобы сравнить с истинной проницаемостью. Использование большего количества входных данных для обучения (рис. 6, б) слегка улучшило результаты прогноза проницаемости. Отметим, что метод Extra Tree показал сравнительно лучшие результаты.

Как видно из рис. 8, наблюдается укрепление связи между логарифмом проницаемости и входными признаками для образцов без трещин по сравнению с трещиноватым образцом. Например, если коэффициент корреляции между логарифмом проницаемости и общей пористостью для трещиноватого образца равняется 0,63 (рис. 8, б), то этот же коэффициент для образцов без трещин составляет 0,85 (рис. 8, а). Подобная крепкая связь наблюдается и для остальных признаков, кроме извилистости, для которой наоборот данный коэффициент уменьшился.

Спрогнозированные с помощью рассмотренных методов машинного обучения проницаемости в сопоставлении с истинными проницаемостями для образцов с трещинами

и без приведены на рис. 9 и 10. Как наглядно показано на рисунках, точность прогноза проницаемости улучшилась, когда из общего количества данных удалили данные трещиноватого образца (рис. 9). Коэффициент достоверности прогноза при обоих делениях входных данных достиг практически 90% (рис. 9). Все три рассмотренных метода показали практически одинаковые результаты. В случае, когда отдельно рассматривали трещиноватый образец (рис. 10), точность прогноза проницаемости была выше, чем когда все образцы были рассмотрены вместе (рис. 6). Из рис. 10 можно заметить, что разброс в распределениях параметров трещиноватого образца передавался в прогнозные значения проницаемости.

Далее проведены два слепых теста с целью спрогнозировать проницаемости мини-объемов трещиноватого образца, обучая и тестируя методы машинного обучения на данных мини-образцов, отобранных из нетрещиноватых образцов (рис. 11, а) и наоборот (рис. 11, б). С этой целью использовали

только метод Extra Trees, т.к. он показал лучшие результаты по сравнению с остальными. Данные в обоих случаях были разделены в соотношении 80/20, т.е. 80% на обучение, а 20% – на тестирование. После того как Extra Trees был обучен и протестирован на данных мини-объемов, отобранных из нетрещиноватых образцов, проницаемости мини-объемов трещиноватого образца были прогнозированы. После этого Extra Trees обучается на данных мини-объемов из трещиноватого образца, чтобы спрогнозировать проницаемости мини-объемов из нетрещиноватых образцов.

Прогнозированная с помощью Extra Trees и истинная проницаемости мини-образцов трещиноватого и нетрещиноватых образцов показаны на рис. 11. Как показывает этот рисунок, машинное обучение спрогнозировало проницаемости с точностью 52% (рис. 11, а) и 59% (рис. 11, б) во время слепых тестов, хотя точность была высокой (около 90%) во время обычных тестов. Это означает, что используемые данные для обучения, обычного и слепых тестов должны иметь похожую структуру, чтобы достичь максимальной точности прогнозов, или же следует использовать уже классифицированные данные образцов, по крайней мере, по их поровой структуре (трещиноватость, однородность и кавернозность).

Заключение

В статье были рассмотрены регрессионные методы Random Forest, XGBoost и Extra Trees для прогнозирования абсолютной проницаемости 408 мини-объемов карбонатных образцов, которые практически полностью состоят из кальцита. Входные данные включали девять параметров и один выходной параметр (абсолютная проницаемость). Параметры мини-объемов были определены при помощи поромасштабного моделирования течения воды в их поровом пространстве с применением специализированного программного пакета Avizo. По результатам исследования можем сделать следующие выводы:

1. Связанная и общая пористости имеют полиномиальную взаимосвязь $\phi_c = -1,48\phi_t^2 + 1,71\phi_t - 0,09$ с коэффициентом

корреляции 0,99. Это позволило определить перколяционный порог пористости для рассмотренных карбонатных образцов, значение которого составило $\approx 5\%$. Это означает, что 5% порового пространства является непроницаемым, и абсолютная проницаемость превращается в ноль.

2. Удельная площадь поверхности зерен линейно коррелирует с общей пористостью соотношениями $S = -0,099\phi_t + 0,037$ и $S = -0,077\phi_t + 0,041$ для трещиноватого и нетрещиноватых образцов соответственно. Коэффициенты корреляции составили 0,72 и 0,61. Это позволяет использовать уравнение Козени-Кармана для оценки абсолютной проницаемости образца при отсутствии данных по удельной площади поверхности.

3. Использование набора данных без какой-либо предобработки привело к прогнозу проницаемости с низкой точностью (9–17%). Использование логарифма проницаемости вместо самой проницаемости позволило повысить точность прогноза абсолютной проницаемости до 86%.

4. Раздельное рассмотрение трещиноватого и нетрещиноватых образцов позволило увеличить точность прогноза абсолютной проницаемости почти до 90%.

5. Прогнозная модель, обученная и протестированная на основе данных мини-объемов трещиноватого образца, плохо прогнозировала проницаемость мини-объемов, отобранных из нетрещиноватых образцов, и наоборот.

6. Метод Extra Trees оказался наиболее точным среди рассмотренных методов машинного обучения для нашей задачи.

В будущем авторы планируют рассматривать другие дополнительно имеющиеся карбонатные образцы, тем самым увеличивая количество мини-объемов, а также использовать изображения образцов из микрокомпьютерной томографии с целью эффективного прогнозирования их абсолютной проницаемости и других макроскопических характеристик. Кроме этого, планируется использовать методы глубокого машинного обучения (искусственные нейронные сети) вместе с регрессионными методами машинного обучения.

ДОПОЛНИТЕЛЬНО

Источник финансирования. Данное исследование было профинансировано Комитетом Науки Министерства науки и высшего образования Республики Казахстан в рамках проекта AP09058419 «Прогнозирование характеристик пористой среды с учетом режимов растворения породы в масштабе пор на основе машинного обучения».

Конфликт интересов. Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Вклад авторов. Все авторы подтверждают соответствие своего авторства международным критериям ICMJE (все авторы внесли существенный вклад в разработку концепции, проведение исследования и под-

готовку статьи, прочли и одобрили финальную версию перед публикацией). Наибольший вклад распределён следующий образом: Асилбеков Б.К. – разработка методики проведения исследования, применение методов машинного обучения, анализ результатов исследования, написание рукописи, Калжанов Н.Е. – обзор и применение методов машинного обучения, Болысбек Д.А. – обработка данных микрокомпьютерной томографии, построение трехмерной цифровой модели цилиндрических образцов, вычисление параметров мини-объемов, Узбекибаев К.Ш. – вычисление параметров мини-объемов, обработка данных с микрокомпьютерной томографии, построение трехмерной цифровой модели цилиндрических образцов, Бекбау Б.Е. – разработка методики проведения исследований, анализ результатов исследований, Кульджабеков А.Б. – разработка методики проведения исследований, анализ результатов исследований.

ADDITIONAL INFORMATION

Funding source. This study was funded by the Committee of Science of the Ministry of Science and Higher Education of the Republic

of Kazakhstan under the project AP09058419 “Prediction of porous media characteristics taking into account rock dissolution patterns at pore scale based on machine learning”.

Competing interests. The authors declare that they have no competing interests.

Authors' contribution. All authors made a substantial contribution to the conception of the work, acquisition, analysis, interpretation of data for the work, drafting and revising the work, final approval of the version to be published and agree to be accountable for all aspects of the work: Bakytzhan K. Assilbekov – development of research methodology, use of machine learning techniques, analysis of research results, writing a manuscript; Nurlykhan Ye. Kalzhanov – review and use of machine learning techniques; Darezhat A. Bolysbek – processing data from microcomputed tomography, building a 3D digital model of cylindrical samples, computing of parameters of small volumes; Kenboy Sh. Uzbekaliyev – computing of parameters of small volumes, processing data from microcomputed tomography; Bakbergen Ye. Bekbau – development of research methodology, analysis of research results; Alibek B. Kuljabekov – development of research methodology, analysis of research results.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Carman P.C. Fluid flow through granular beds // Chem Eng Res Des. 1997. Vol. 75. P. 32–48. doi:10.1016/S0263-8762(97)80003-2.
2. Eichheimer P., Thielmann M., Fujita W., et al. Combined numerical and experimental study of microstructure and permeability in porous granular media // Solid Earth. 2020. Vol. 11, N 3. P. 1079–1095. doi:10.5194/se-11-1079-2020.
3. Mostaghimi P., Blunt M.J., Bijeljic B. Computations of Absolute Permeability on Micro-CT Images // Math Geosci. 2013. Vol. 45, N 1. P. 103–125. doi:10.1007/s11004-012-9431-4.
4. Luquot L., Rodriguez O., Gouze P. Experimental Characterization of Porosity Structure and Transport Property Changes in Limestone Undergoing Different Dissolution Regimes // Transp Porous Media. 2014. Vol. 101, N 3. P. 507–532. doi:10.1007/s11242-013-0257-4.
5. Noiriel C., Gouze P., Bernard D. Investigation of porosity and permeability effects from microstructure changes during limestone dissolution // Geophys Res Lett. 2004. Vol. 31, N 24. P. 1–4. doi:10.1029/2004GL021572.
6. Smith M.M., Sholokhova Y., Hao Y., Carroll S.A. CO₂-induced dissolution of low permeability carbonates. Part I: Characterization and experiments // Adv Water Resour. 2013. Vol. 62. P. 370–387. doi:10.1016/j.advwatres.2013.09.008.
7. Koponen A., Kataja M., Timonen J. Permeability and effective porosity of porous media // Phys Rev E. 1997. Vol. 56, N 3. P. 3319–3325. doi:10.1103/PhysRevE.56.3319.
8. Mavko G., Nur A. The effect of a percolation threshold in the Kozeny-Carman relation // GEOPHYSICS. 1997. Vol. 62, N 5. P. 1480–1482. doi:10.1190/1.1444251.
9. Bernabe Y., Brace W.F., Evans B. Permeability, porosity and pore geometry of hot-pressed calcite // Mech Mater. 1982. Vol. 1, N 3. P. 173–183. doi:10.1016/0167-6636(82)90010-2.
10. Nishiyama N., Yokoyama T. Permeability of porous media: Role of the critical pore size // J Geophys Res Solid Earth. 2017. Vol. 122, N 9. P. 6955–6971. doi:10.1002/2016JB013793.
11. Elmorsy M., El-Dakhkhni W., Zhao B. Generalizable Permeability Prediction of Digital Porous Media via a Novel Multi-Scale 3D Convolutional Neural Network // Water Resour Res. 2022. Vol. 58, N 3. doi:10.1029/2021WR031454.

12. Tian J., Qi C., Sun Y., Yaseen Z.M., Pham B.T. Permeability prediction of porous media using a combination of computational fluid dynamics and hybrid machine learning methods // *Eng Comput.* 2021. Vol. 37, N 4. P. 3455–3471. doi:10.1007/s00366-020-01012-z.
13. Mohammadian E., Kheirollahi M., Liu B., Ostadhassan M., Sabet M. A case study of petrophysical rock typing and permeability prediction using machine learning in a heterogenous carbonate reservoir in Iran // *Sci Rep.* 2022. Vol. 12, N 1. P. 4505. doi:10.1038/s41598-022-08575-5.
14. Rezaee R., Ekundayo J. Permeability Prediction Using Machine Learning Methods for the CO₂ Injectivity of the Precipice Sandstone in Surat Basin, Australia // *Energies.* 2022. Vol. 15, N 6. P. 2053. doi:10.3390/en15062053.
15. Gholami R., Shahraki A.R., Jamali Paghaleh M. Prediction of Hydrocarbon Reservoirs Permeability Using Support Vector Machine // *Math Probl Eng.* 2012. Vol. 2012. P. 1–18. doi:10.1155/2012/670723.
16. Erofeev A., Orlov D., Ryzhov A., Koroteev D. Prediction of Porosity and Permeability Alteration Based on Machine Learning Algorithms // *Transp Porous Media.* 2019. Vol. 128, N 2. P. 677–700. doi:10.1007/s11242-019-01265-3.
17. Tembely M., AlSumaiti A.M., Alameri W. A deep learning perspective on predicting permeability in porous media from network modeling to direct simulation // *Comput Geosci.* 2020. Vol. 24, N 4. P. 1541–1556. doi:10.1007/s10596-020-09963-4.
18. Akasheva Z., Bolysbek D., Assilbekov B. Study of carbonate rock dissolution using x-ray microcomputed tomography: impact of acid flow rate // *News Natl Acad Sci Repub Kazakhstan Ser Geol Tech Sci.* 2023. Vol. 1, N 457. P. 20–32. doi:10.32014/2023.2518-170X.256.
19. Shahani N.M., Zheng X., Liu C., Hassan F.U., Li P. Developing an XGBoost Regression Model for Predicting Young's Modulus of Intact Sedimentary Rocks for the Stability of Surface and Subsurface Structures // *Front Earth Sci.* 2021. Vol. 9. doi:10.3389/feart.2021.761990.
20. Hameed M.M., AlOmar M.K., Khaleel F., Al-Ansari N. An Extra Tree Regression Model for Discharge Coefficient Prediction: Novel, Practical Applications in the Hydraulic Sector and Future Research Directions // *Math Probl Eng.* 2021. P. 1–19. doi:10.1155/2021/7001710.

REFERENCES

1. Carman PC. Fluid flow through granular beds. *Chem Eng Res Des.* 1997;75:S32–S48. doi:10.1016/S0263-8762(97)80003-2.
2. Eichheimer P, Thielmann M, Fujita W, et al. Combined numerical and experimental study of microstructure and permeability in porous granular media. *Solid Earth.* 2020;11(3):1079–1095. doi:10.5194/se-11-1079-2020.
3. Mostaghimi P, Blunt MJ, Bijeljic B. Computations of Absolute Permeability on Micro-CT Images. *Math Geosci.* 2013;45(1):103–125. doi:10.1007/s11004-012-9431-4.
4. Luquot L, Rodriguez O, Gouze P. Experimental Characterization of Porosity Structure and Transport Property Changes in Limestone Undergoing Different Dissolution Regimes. *Transp Porous Media.* 2014;101(3):507–532. doi:10.1007/s11242-013-0257-4.
5. Noiriell C, Gouze P, Bernard D. Investigation of porosity and permeability effects from microstructure changes during limestone dissolution. *Geophys Res Lett.* 2004;31(24):1–4. doi:10.1029/2004GL021572.
6. Smith MM, Sholokhova Y, Hao Y, Carroll SA. CO₂-induced dissolution of low permeability carbonates. Part I: Characterization and experiments. *Adv Water Resour.* 2013;62:370–387. doi:10.1016/j.advwatres.2013.09.008.
7. Koponen A, Kataja M, Timonen J. Permeability and effective porosity of porous media. *Phys Rev E.* 1997;56(3):3319–3325. doi:10.1103/PhysRevE.56.3319.
8. Mavko G, Nur A. The effect of a percolation threshold in the Kozeny-Carman relation. *GEOPHYSICS.* 1997;62(5):1480–1482. doi:10.1190/1.1444251.
9. Bernabe Y, Brace WF, Evans B. Permeability, porosity and pore geometry of hot-pressed calcite. *Mech Mater.* 1982;1(3):173–183. doi:10.1016/0167-6636(82)90010-2.
10. Nishiyama N, Yokoyama T. Permeability of porous media: Role of the critical pore size. *J Geophys Res Solid Earth.* 2017;122(9):6955–6971. doi:10.1002/2016JB013793.
11. Elmorsy M, El-Dakhkhni W, Zhao B. Generalizable Permeability Prediction of Digital Porous Media via a Novel Multi-Scale 3D Convolutional Neural Network. *Water Resour Res.* 2022;58(3). doi:10.1029/2021WR031454.
12. Tian J, Qi C, Sun Y, Yaseen ZM, Pham BT. Permeability prediction of porous media using a combination of computational fluid dynamics and hybrid machine learning methods. *Eng Comput.* 2021;37(4):3455–3471. doi:10.1007/s00366-020-01012-z.
13. Mohammadian E, Kheirollahi M, Liu B, Ostadhassan M, Sabet M. A case study of petrophysical rock typing and permeability prediction using machine learning in a heterogenous carbonate reservoir in Iran. *Sci Rep.* 2022;12(1):4505. doi:10.1038/s41598-022-08575-5.

14. Rezaee R, Ekundayo J. Permeability Prediction Using Machine Learning Methods for the CO₂ Injectivity of the Precipice Sandstone in Surat Basin, Australia. *Energies*. 2022;15(6):2053. doi:10.3390/en15062053.

15. Gholami R, Shahraki AR, Jamali Paghaleh M. Prediction of Hydrocarbon Reservoirs Permeability Using Support Vector Machine. *Math Probl Eng*. 2012;2012:1–18. doi:10.1155/2012/670723.

16. Erofeev A, Orlov D, Ryzhov A, Koroteev D. Prediction of Porosity and Permeability Alteration Based on Machine Learning Algorithms. *Transp Porous Media*. 2019;128(2):677–700. doi:10.1007/s11242-019-01265-3.

17. Tembely M, AlSumaiti AM, Alameri W. A deep learning perspective on predicting permeability in porous media from network modeling to direct simulation. *Comput Geosci*. 2020;24(4):1541–1556. doi:10.1007/s10596-020-09963-4.

18. Akasheva Z, Bolysbek D, Assilbekov B. Study of carbonate rock dissolution using x-ray microcomputed tomography: impact of acid flow rate. *News Natl Acad Sci Repub Kazakhstan Ser Geol Tech Sci*. 2023;1(457):20–32. doi:10.32014/2023.2518-170X.256.

19. Shahani NM, Zheng X, Liu C, Hassan FU, Li P. Developing an XGBoost Regression Model for Predicting Young's Modulus of Intact Sedimentary Rocks for the Stability of Surface and Subsurface Structures. *Front Earth Sci*. 2021;9. doi:10.3389/feart.2021.761990.

20. Hameed MM, AlOmar MK, Khaleel F, Al-Ansari N. An Extra Tree Regression Model for Discharge Coefficient Prediction: Novel, Practical Applications in the Hydraulic Sector and Future Research Directions. Armaghani D, ed. *Math Probl Eng*. 2021;2021:1–19. doi:10.1155/2021/7001710.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Асилбеков Бакытжан Калжанович

PhD, ORCID 0000-0002-0368-0131

e-mail: assibekov.b@gmail.com.

Қалжанов Нұрлыхан Ерланұлы

ORCID 0009-0008-5776-0971

e-mail: nurkal022@gmail.com.

***Болысбек Дәрежат Абілсеитұлы**

ORCID 0000-0001-8936-3921

e-mail: bolysbek.darezhat@gmail.com.

Ўзбекалиев Кенбой Шералиугли

ORCID 0009-0000-6917-4963

e-mail: kzkenbai@gmail.com.

Бекбау Бақберген Ермекбайұлы

PhD, ORCID 0000-0003-2410-1626

e-mail: bakbergen@gmail.com.

Кульджабеков Алибек Бахиджанович

PhD, ORCID 0000-0003-4384-6463

e-mail: alibek.kuljabekov@gmail.com.

AUTHORS' INFO

Bakytzhan K. Assilbekov

PhD, ORCID 0000-0002-0368-0131

e-mail: assibekov.b@gmail.com.

Nurlykhan Ye. Kalzhanov

ORCID 0009-0008-5776-0971

e-mail: nurkal022@gmail.com.

***Darezhat A. Bolysbek**

ORCID 0000-0001-8936-3921

e-mail: bolysbek.darezhat@gmail.com.

Kenboy Sh. Uzbekaliyev

ORCID 0009-0000-6917-4963

e-mail: kzkenbai@gmail.com.

Bakbergen Ye. Bekbau

PhD, ORCID 0000-0003-2410-1626

e-mail: bakbergen@gmail.com.

Alibek B. Kuljabekov

PhD, ORCID 0000-0003-4384-6463

e-mail: alibek.kuljabekov@gmail.com.

*Автор, ответственный за переписку/Corresponding Author