

Физически обусловленное машинное обучение для прогнозирования газовой проницаемости стандартных карбонатных образцов керна по стекам низкоразрешённых микротомографических изображений

Р. И. Кадыров¹, Т. Х. Нгуен², Е. О. Стаценко³

Казанский федеральный университет (Институт геологии и нефтегазовых технологий), Казань, Россия

¹ ORCID: 0000-0002-7566-6312, rail7777@gmail.com

² ORCID: 0000-0001-6155-9017, thanhtu154@gmail.com

³ ORCID: 0000-0001-6259-1713, e.statsenko@yahoo.com

Аннотация

В работе предложен физически обусловленный рабочий процесс для прогнозирования газовой проницаемости карбонатных коллекторов непосредственно по низкоразрешённым микротомографическим (микро-КТ) изображениям. Стандартные образцы керна диаметром 30 мм были просканированы с разрешением 34,6–36 мкм/воксель; из 71 образца получено 52 327 изображений в оттенках серого (737 срезов на образец). Каждому срезу было присвоено синтетическое значение трёхмерной проницаемости, основанное на фрактальной аналитической модели, после чего оно было нормировано с использованием либо гармонического среднего, либо агрегирования по принципу «бутылочного горлышка» относительно экспериментальных измерений на уровне всего керна. Изображения в оттенках серого и логарифмированные метки проницаемости использовались для обучения модели трансформера со скользящими окнами (Swin Transformer), предварительно обученной на базе изображений ImageNet. Были независимо разработаны две модели: одна с использованием гармонического усреднения, другая – на основе подхода бутылочного горлышка. Обе модели продемонстрировали стабильную сходимость, несмотря на сильную асимметрию распределения данных. Модель с гармоническим средним достигла $R^2 = 0,904$ на валидационной выборке, тогда как модель показала $R^2 = 0,879$. Хотя более высокое значение R^2 отражает лучшее соответствие общей тенденции, модель бутылочного горлышка при слепом тестировании на десяти независимых образцах ($0,4\text{--}2300 \text{ мкм}^2 \times 10^{-3}$) уменьшила MAE с 165 до 104 $\text{мкм}^2 \times 10^{-3}$ (–37 %) и RMSE с 255 до 140 $\text{мкм}^2 \times 10^{-3}$ (–45 %) по сравнению с моделью на гармоническом среднем. Метод обеспечивает быстрый и интерпретируемый прогноз проницаемости исключительно на основе исходных микро-КТ срезов, без необходимости сегментации изображений или 3D-реконструкции. Предложенный подход демонстрирует устойчивую работу на широком диапазоне стандартных карбонатных образцов и эффективно захватывает тренды проницаемости даже при наличии структурной неоднородности. Хотя образцы с крайне крупными трещинами или кавернами могут вносить локальные несоответствия в разметку из-за ограничений оценки по срезам, такие случаи редки и могут быть систематически учтены в будущих работах. В целом результаты подчёркивают высокий потенциал физически-обусловленного машинного обучения для ускорения цифрового анализа керна и получения надёжных прогнозов проницаемости по изображениям для сложных карбонатных коллекторов.

Ключевые слова: проницаемость, карбонаты, микро-КТ, цифровой керн, поровая структура, стандартный образец керна, физически обусловленное машинное обучение, анализ 2D-изображений.

1. Введение

Определение фильтрационно-емкостных свойств горных пород, таких как пористость и абсолютная проницаемость, является необходимым условием для разработки нефтегазовых месторождений и повышения их нефтеотдачи [1]. Оценка свойств коллектора может быть затруднена из-за неоднородности и сложности строения горных пород, которые значительно варьируются в зависимости от различных геологических формаций и истории погружения [2,3]. В частности, проницаемость, являясь одной из наиболее фундаментальных физических характеристик пористого материала, в значительной степени определяется структурой порового пространства [4–6].

В настоящее время можно выделить три основных подхода к оценке проницаемости пород-коллекторов: экспериментальные измерения, эмпирические модели и цифровая физика горных пород. Экспериментальные измерения проводятся на стандартных образцах керна и требуют значительных временных, трудовых и финансовых затрат [7]. Существуют также эмпирические и теоретические модели, включая известное уравнение Козени–Кармана, связывающих пористость, проницаемость и другие свойства резервуаров [8,9]. Хотя эти эмпирические модели являются эффективными и экономичными, однако, часто их универсальность ограничена: появляется необходимость в подборе параметров для различных типов пород и конкретных особенностей ее структуры [10]. Свойства пород также можно оценить с помощью численных моделирований, однако такие методы требуют реконструкции трёхмерных (3D) поровых сетей, что связано с высокими требованиями к вычислительным ресурсам и скрытыми неопределённостями, включающие потерю разрешения и искажения структуры [11]. Кроме того, результаты численных моделирований бывает сложно сопоставить с экспериментальными данными, из-за расхождения в размерах образцов [6,12], особенно в случае высокой гетерогенности некоторых типов коллекторов, например, таких как карбонаты [13].

Машинное обучение рассматривается в качестве альтернативного подхода для оценки фильтрационно-емкостных свойств коллекторов. Такие методы, как рентгеновская микротомография, позволяют получать изображения внутренней структуры пористой среды, служащие входными данными для алгоритмов машинного обучения [14]. Методы машинного и глубокого обучения способны прогнозировать свойства пород по изображениям за считанные секунды при минимальных вычислительных затратах [1,14,15]. Это даёт существенные преимущества по сравнению с экспериментальными измерениями и численным моделированием, которые не позволяют эффективно обрабатывать сразу несколько образцов. В ряде работ успешно демонстрировалась возможность предсказания пористости и проницаемости на основе изображений. Так, глубокое обучение применялось для оценки проницаемости по 2D-изображениям шлифов высокого разрешения, показав высокую точность и скорость метода [16]. Также было показано, что физически-обусловленное обучение может с высокой точностью и на порядки быстрее традиционного моделирования предсказывать проницаемость синтетических 2D-пористых сред на основе изображений, включая случаи, где классические эмпирические уравнения оказываются неэффективны [17]. Сверточная нейронная сеть использовалась для оценки пористости по изображениям песчаника Береа с сегментацией и без неё [18], продемонстрировав хорошее соответствие экспериментальным данным [19]. Они также показали, что сверточные нейронные сети могут успешно работать с микротомографическими изображениями в оттенках серого. В работе [20] методы неглубокого и глубокого обучения были применены к 3D микротомографическим данным для прогнозирования проницаемости в сравнении с численным моделированием: глубокие сети показали лучшие результаты по сравнению с градиентным бустингом и линейной регрессией, а методы машинного обучения показали существенный выигрыш в скорости вычислений в сравнении с прямым моделированием на основе решеточных уравнений Больцмана.

Несмотря на прогресс, модели машинного обучения сталкиваются с трудностями при переносе на новые данные из-за переобучения и ограниченного числа обучающих примеров. Особенно это актуально при работе с 3D-данными, требующими значительных вычислительных ресурсов. Одним из перспективных подходов является разделение 3D-объёма на стек 2D-срезов и обучение моделей на этом множестве изображений [12,14]. Такой подход особенно хорошо работает при прогнозе пористости, однако, при оценке проницаемости возникают дополнительные сложности, связанные с её сильной нелинейной зависимостью от 3D геометрии пор, их связности и каналов фильтрации. Для преодоления этих ограничений предпринимались попытки связать свойства породы, извлечённые из 2D изображений, с 3D структурой. В работе [17] была показана возможность быстрой и точной оценки 2D-проницаемости синтетических изображений пористых сред с использованием физически-информированной сверточной нейронной сети, обученной на данных численного моделирования фильтрации на основе решеточных уравнений Больцмана. В исследовании [21] пористость и абсолютная проницаемость карбонатных кернов предсказывались на основе статистических 2D-признаков пор, извлечённых из стеков микротомографических срезов высокого разрешения (0,8 – 14 мкм) с помощью сегментации пор методом водораздела (watershed), а итоговое значение свойства определялось объединяющей мета-моделью, которая учитывала предсказания нескольких независимых моделей машинного обучения. Ещё одним подходом [22] является аналитическая оценка проницаемости пористых сред по 2D-изображениям высокого разрешения, основанный на сочетании уравнения Козени–Кармана и фрактальной теории. Метод позволяет рассчитывать проницаемость без необходимости 3D-реконструкции структуры пор, используя параметры порового пространства, извлечённые из 2D-срезов, и демонстрирует хорошее согласование с результатами численного моделирования методом решетчатых уравнений Больцмана.

Тем не менее, у этих подходов есть ряд ограничений. Некоторые из них сосредоточены на прогнозировании двумерной проницаемости, что затрудняет их применение для оценки фильтрационных свойств в реальных трёхмерных образцах. Проверка моделей часто осуществляется с использованием данных численного моделирования, а не экспериментальных измерений. Использование высокоразрешающих изображений (до нескольких микрон) ограничивает размеры анализируемых образцов, что особенно критично для карбонатов с выраженной гетерогенностью и необходимостью соблюдения условий репрезентативности. Кроме того, эти подходы требуют значительных усилий по подготовке данных – сегментации, извлечению признаков, а также последующего обучения мета-моделей или выполнения сложных аналитических расчётов.

В настоящем исследовании мы предлагаем гибридный рабочий процесс, сочетающий микротомографию с низким разрешением (размер вокселя 34,6–36 мкм) и машинное обучение для быстрой оценки газовой проницаемости стандартных карбонатных кернов на масштабе всего цилиндра по стекам исходных двумерных срезов. Основная идея заключается в том, чтобы использовать эмпирические расчёты для обучения модели машинного обучения, способной предсказывать трёхмерную проницаемость по отдельным микротомографическим срезам без сегментации, а затем применить распределение этих предсказаний по всему стеку для оценки проницаемости всего образца.

2. Материалы и методы

2.1. Микро-КТ сканирование стандартных образцов керна

Для проведения исследования была подготовлена коллекция из 71 стандартного карбонатного образца (цилиндры высотой и диаметром по 30 мм). Стоит отметить, что из набора были исключены образцы с выраженной кавернозностью или трещиноватостью, поскольку наличие таких вторичных преобразований затрудняет корректное

применение выбранного подхода, ориентированного в основном на матричную пористость.

Образцы сканировались с помощью микрофокусной и нанофокусной рентгеновской системы компьютерной томографии General Electric Phoenix v|tome|x S 240 (Германия) с разрешением 34,6–36,0 мкм. При сканировании поддерживались следующие параметры: ток рентгеновской трубки — 150 мкА, напряжение — 150 кВ, число проекций — 1200 с коэффициентом усреднения 3 и временем экспозиции 200 мс на проекцию.

Полученные проекции реконструировались в 3D-изображения с использованием программного обеспечения phoenix datos|x. Для устранения краевых артефактов и стандартизации данных во всех образцах была выделена цилиндрическая область интереса размером 737×737 вокселей по диаметру и высоте, гарантированно находящаяся внутри границ каждого стандартного образца керна. Полученный объём затем преобразовывался в стек 2D-срезов вдоль оси z, совпадающей с осью цилиндра, по 737 изображений на каждый стек (рис. 1).




Рис. 1. Процесс низкоразрешающей микро-КТ: 737 аксиальных срезов, извлечённых из карбонатного керна диаметром 30 мм после наложения цилиндрической маски

2.2. Экспериментальные измерения

Открытая пористость и газовая проницаемость с коррекцией по Клинкенбергу для каждого образца были измерены с помощью прибора ПИК-ПП для анализа проницаемости и пористости (Россия). Диапазон значений проницаемости в исследуемой коллекции образцов составляет от 0,1 до $2192 \text{ мкм}^2 \times 10^{-3}$, что отражает высокую степень неоднородности карбонатов. На совмещённом боксплоте (рис. 2) распределение открытой пористости компактное: медиана составляет 9,3 %, внутривквартильный размах охватывает ~6–13 %, и менее 5 % срезов превышают 20 %, т.е. пористость слабо варьирует вокруг низко-среднего значения. Проницаемость, напротив, распределена сильно неравномерно. Четверть измерений находится на нижнем пределе чувствительности — $0,1 \text{ мкм}^2 \times 10^{-3}$, при этом бокс уже простирается до медианы в $7 \text{ мкм}^2 \times 10^{-3}$ и верхнего квартиля около $115 \text{ мкм}^2 \times 10^{-3}$, а «усы» и выбросы выходят за $1100 \text{ мкм}^2 \times 10^{-3}$. Если ограничить анализ срезами с проницаемостью $> 1 \text{ мкм}^2 \times 10^{-3}$ (≈ 65 % выборки), то большинство значений сосредоточены в диапазоне $10\text{--}200 \text{ мкм}^2 \times 10^{-3}$, и лишь немногие образцы превышают $1000 \text{ мкм}^2 \times 10^{-3}$, что подтверждает: способность к фильтрации значительно более гетерогенна, чем пористость, в исследуемых кернах.




Рис. 2. Боксплот открытой пористости (%) и проницаемости (10^{-3} мкм²) по 71 карбонатному образцу стандартного керна; красные линии обозначают медианы

2.3. Маркирование изображений

Ключевым этапом в построении физически информированной модели является формирование достоверной и репрезентативной разметки, отражающей внутреннюю фильтрационную неоднородность керна. В условиях, когда машинное обучение применяется к 2D-срезах, необходимо обеспечить корректное сопоставление каждого изображения со значением, отражающим проницаемость. Для решения этой задачи в данной работе реализован подход, основанный на фрактальной модели [22], согласно которой проницаемость пористой среды может быть приближённо оценена по 2D-изображениям с использованием геометрических характеристик порового пространства, таких как пористость, минимальный и максимальный радиус пор, извилистость и фрактальная размерность. Ранее в работе [14] было показано, что при использовании микротомографических изображений с разрешением 38 мкм модели машинного обучения способны с достаточной точностью извлекать ключевые структурные признаки карбонатных пород, несмотря на ограниченность пространственного разрешения и наличие неразрешённых пор.

В качестве основы для такой модели используется метод сегментации порового пространства, при котором границы пор подбираются индивидуально для каждого образца так, чтобы средняя 2D-пористость по стеку соответствовала экспериментально измеренной 3D-пористости. Это обеспечивает учёт неразрешённых пор и адаптацию процедуры сегментации к конкретным особенностям каждого образца.

На полученных сегментированных 2D-изображениях с помощью алгоритма водораздела (watershed) определялись контуры пор [23], после чего для каждой поровой области на основе алгоритма преобразования расстояний (distance transform) [21] рассчитывался максимальный радиус пор r_{\max} на плоскости. Также для всей сегментированной структуры пор определялась двумерная фрактальная размерность на основе метода подсчета в ячейках (box counting) [24]. Поскольку пространственное разрешение микротомографических изображений в настоящем исследовании является ограниченным (34,6–36 мкм), определение минимального радиуса пор r_{\min} оказывается затруднено. Согласно многочисленным исследованиям, минимальные радиусы пор на 2D-срезах карбонатных пород оказываются меньше 1 мкм [25,26], поэтому, для унификации расчётов и учёта неразрешённых пор в данной работе принято приближённое значение минимального радиуса пор r_{\min} равным 1 мкм для всех изображений.

Далее, на основе аналитического подхода, предложенного в работе [22], для каждого сегментированного изображения были последовательно рассчитаны ключевые параметры 3D порового пространства.

При этом объемная пористость принимается равной пористости изображения:

$$\varphi_{3D} = \varphi_{2D} \quad (1)$$

После этого рассчитывается параметр трансформационной размерности D_T , отражающий изменение характера заполнения порового пространства при переходе от площади к объёму.

$$D_T = \left[\frac{(5-4D_T) \ln(\varphi_{3D})}{\ln\left(\frac{r_{min}}{r_{max}}\right)} + 1 \right] + \left\{ \frac{(5-4D_T) \ln(\varphi_{3D})}{\ln\left(\frac{r_{min}}{r_{max}}\right)} \times \left\{ \frac{\log \left[3 - \frac{(5-4D_T) \ln(\varphi_{3D})}{\ln\left(\frac{r_{min}}{r_{max}}\right)} \right]}{\log(\varphi_{3D})} - \frac{\log \left[2 - \frac{(5-4D_T) \ln(\varphi_{3D})}{\ln\left(\frac{r_{min}}{r_{max}}\right)} \right]}{\log(\varphi_{3D})} \right\} \right\} \quad (2)$$

В случае, если значение D_T превышало 1,125, оно ограничивалось значением 1,124999, чтобы избежать нарушения физической интерпретации модели (например, инверсии, где $r_{3D,min} > r_{3D,max}$) [22].

Далее на основе параметра трансформационной размерности D_T , значения пористости φ_{3D} и соотношения поровых радиусов r_{min} и r_{max} на 2D-срезах рассчитывалась трёхмерная фрактальная размерность D_f :

$$D_f = 3 - \frac{(5-4D_T) \ln(\varphi_{3D})}{\ln(r_{min}/r_{max})} \quad (3)$$

Следующим шагом является расчет объема образца, в пределах которого оцениваются характеристики порового пространства:

$$V = \left\{ \frac{\pi D_f r_{max}^{3-D_T} (2r_{max})^{\frac{(4D_T-4)(3-D_T)}{5-4D_T}}}{4\varphi_{3D}(3-D_T-D_f)} \left[1 - \left(\frac{r_{min}}{r_{max}} \right)^{\frac{3-D_T-D_f}{5-4D_T}} \right] \right\}^{\frac{3(5-4D_T)}{3-D_T}} \quad (4)$$

Затем производится расчет максимального ($r_{3D,max}$) и минимального ($r_{3D,min}$) радиуса пор в 3D-пространстве:

$$r_{3D,max} = \frac{r_{max}}{\left[\sqrt[3]{V}/(2r_{max}) \right]^{\frac{4D_T-4}{5-4D_T}}}; \quad r_{3D,min} = \frac{r_{min}}{\left[\sqrt[3]{V}/(2r_{min}) \right]^{\frac{4D_T-4}{5-4D_T}}} \quad (5)$$

В конечном счете, с помощью рассчитанных параметров для 3D-пространства вычисляется 3D-проницаемость:

$$K_{3D} = \frac{\pi D_f 2^{D_T} r_{3D,max}^{D_f} (r_{3D,max}^{3-D_f+D_T} - r_{3D,min}^{3-D_f+D_T})}{16V^{\frac{1+D_T}{3}} (3-D_f+D_T)} \quad (6)$$

Таким образом, для каждого изображения в стеке было рассчитано индивидуальное значение 3D-проницаемости, и каждый образец получил 737 таких значений. Хотя низкое разрешение и искажения форм пор при сегментации могут приводить к расхождениям между рассчитанными и экспериментальными величинами, полученное распределение 3D-проницаемостей вдоль оси цилиндрического образца чётко демонстрирует внутреннюю фильтрационную неоднородность образца.

2.4. Агрегация и нормализация

Для каждого образца на предыдущем этапе было получено 737 индивидуальных значений проницаемости — по одному для каждого 2D-среза в стеке. Однако для обучения модели, сопоставимой с экспериментальными измерениями, необходимо привести эти данные к единой величине, характеризующей проницаемость всего образца. Наиболее универсальным и потенциально точным решением в этом случае могла бы стать реализация мета-модели, обучаемой на основе известных экспериментальных значений и локальных прогнозов по срезам. Такая модель могла бы автоматически находить оптимальное агрегирующее преобразование. Однако ограниченное количе-

ство экспериментально охарактеризованных образцов в доступном датасете не позволяет реализовать этот подход без риска переобучения.

Для перехода от распределённого набора значений 3D-проницаемости, рассчитанных по срезам, к единой оценке проницаемости всего образца, были протестированы 2 подхода. Первый основан на использовании гармонического среднего, которое широко применяется в задачах фильтрации в пористых средах, когда отдельные участки с различной проницаемостью соединены последовательно вдоль направления потока, как это имеет место при вертикальном фильтрационном потоке через цилиндрический керн.

В такой модели наиболее низкопроницаемые участки оказывают наибольшее влияние на общее сопротивление потоку, что делает гармоническое среднее наиболее адекватным типом усреднения для оценки эффективной проницаемости по вертикальному стеку. Гармоническое среднее рассчитывается по следующей формуле:

$$K_{harm} = \frac{N}{\sum_{i=1}^N \frac{1}{K_{3D}(i)}}, \quad (7)$$

где $K_{3D}(i)$ — значение 3D-проницаемости на i -м срезе, $N = 737$ — общее число изображений в стеке.

Использование этой формулы позволяет получить усреднённое значение проницаемости образца, физически эквивалентное суммарному сопротивлению при прохождении фильтрационного потока через последовательно соединённые участки с переменной проницаемостью. Данный подход не требует дополнительных параметров или калибровки и может быть использован в качестве базового способа агрегирования.

Второй подход основан на концепции бутылочного горлышка, согласно которой общая проницаемость пористой среды определяется наиболее низкопроницаемыми участками, ограничивающими поток. Такой подход особенно актуален для гетерогенных карбонатных пород, где даже кратковременное сужение порового канала может значительно снизить эффективную проницаемость всего образца.

Для реализации этого метода стек из 737 срезов анализировался с использованием скользящего окна шириной в 5 срезов, что снижает влияние случайных выбросов или ошибок сегментации. В пределах каждого окна вычислялось арифметическое среднее значений 3D-проницаемости, после чего из всех таких окон выбиралось минимальное среднее значение:

$$k_b(i) = \frac{1}{\omega} \sum_{j=i}^{i+\omega-1} K_{3D}(j), \quad i = 1, \dots, N - \omega + 1 \quad (8)$$

$$K_{bottle} = \min_{i=1}^{N-\omega+1} k_b(i) \quad (9)$$

где $K_{3D}(i)$ — значение 3D проницаемости на i -срезе, ω — ширина окна равная 5, $N = 737$ — общее число срезов в стеке.

После расчёта 3D-проницаемостей для каждого изображения стека возникла необходимость корректировки их масштаба для сопоставления с экспериментальными данными. Для каждого образца было получено 737 локальных значений $K_{3D}(i)$ и одно экспериментально измеренное значение проницаемости K_{exp} . Агрегирование локальных значений через гармоническое среднее или модель бутылочного горлышка позволяло получить интегральную оценку проницаемости, однако из-за приближённого характера расчётов эти оценки могли систематически отличаться от экспериментальных значений. Для устранения этого расхождения была проведена нормализация, заключающаяся в масштабировании всех локальных значений проницаемости на постоянный коэффициент C , определяемый индивидуально для каждого способа агрегации. В случае гармонического среднего коэффициент нормализации C_{harm} рассчитывался так, чтобы гармоническое среднее нормированных проницаемостей точно соответствовало экспериментальной величине:

$$K_{exp} = \frac{N}{\sum_{i=1}^N \frac{1}{C_{harm} \cdot K_{3D}(i)}} \quad (10)$$

что дает выражение:

$$C_{harm} = \frac{K_{exp}}{N} \sum_{i=1}^N \frac{1}{K_{3D}(i)}. \quad (11)$$

Для модели бутылочного горлышка коэффициент C_{bottle} определялся таким образом, чтобы минимальное среднее значение проницаемости по окну шириной 5 слайсов после нормализации совпадало с K_{exp} :

$$K_{exp} = \min_{i=1, \dots, N-\omega+1} \frac{1}{\omega} \sum_{j=i}^{i+\omega-1} C_{bottle} \cdot K_{3D}(j), \quad (12)$$

откуда:

$$C_{bottle} = \frac{\omega K_{exp}}{\min_{i=1, \dots, N-\omega+1} \sum_{j=i}^{i+\omega-1} K_{3D}(j)}. \quad (13)$$

Применение нормализации позволило сохранить форму распределения проницаемости вдоль стека и одновременно обеспечить соответствие агрегированных прогнозов реальным экспериментальным значениям. Таким образом, была произведена разметка всех 2D-изображений стека, каждому из которых было сопоставлено нормированное значение 3D-проницаемости. В результате были сформированы два независимых датасета: один на основе подхода агрегирования через гармоническое среднее, второй — на основе модели бутылочного горлышка.

2.5. Архитектура модели для предсказания проницаемости

Для решения задачи предсказания проницаемости по микротомографическим изображениям использовалась архитектура Swin Transformer [27]. В отличие от традиционных сверточных сетей (CNN), Swin Transformer использует механизм самовнимания для моделирования как локальных, так и глобальных зависимостей в изображении. Архитектура построена иерархически: изображение делится на небольшие окна, внутри которых применяется локальное самовнимание, а затем через сдвиг окон обеспечивается взаимодействие между соседними участками (рис. 3). Такая иерархическая структура позволяет одновременно улавливать мелкомасштабные поровые детали и дальнедействующие связи на всём изображении.

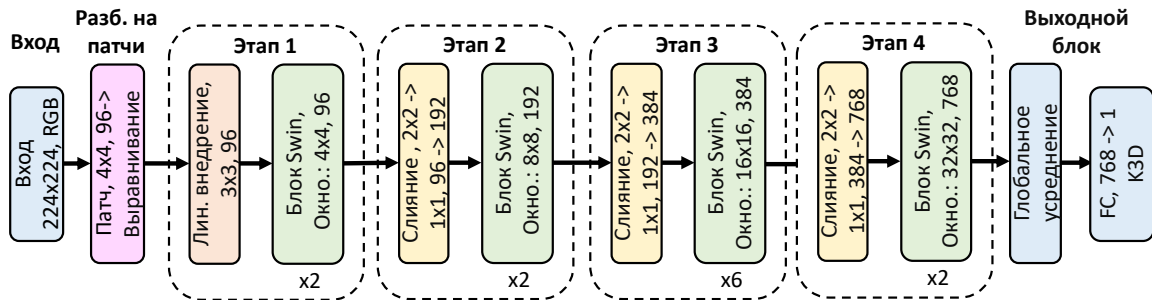


Рис. 3. Архитектура модели Swin Transformer, использованной для предсказания газовой проницаемости по срезам

Для уменьшения влияния ограниченного объёма данных было применено обучение с использованием предобученных весов на наборе ImageNet-1k. На этапе подготовки данных все 16-битные микротомографические изображения нормировались по интенсивности, маскировались по контуру цилиндра, а затем масштабировались до размера 224×224 пикселя с использованием интерполяции по площади. Дополнительно применялась аугментация данных путём случайных поворотов изображений на 0° , 90° , 180° и 270° , что позволило повысить обобщающую способность модели.

В рамках исследования были обучены две отдельные модели Swin Transformer. Первая модель обучалась на датасете, сформированном с использованием агрегированных значений проницаемости по гармоническому среднему, вторая — на датасете с использованием модели бутылочного горлышка. В каждом случае объём данных составлял 52 327 изображений карбонатных образцов (71 керн \times 737 срезов). Для каждого изоб-

ражения формировалась обучающая метка в виде нормированного значения 3D-проницаемости.

Важно отметить, что из-за большого разброса значений 3D-проницаемости обучающая выборка характеризовалась сильно неравномерным распределением с охватом нескольких порядков величины. Для стабилизации процесса обучения и обеспечения корректной обработки как малых, так и больших значений модель обучалась на логарифмах проницаемости. Целью регрессии было предсказание логарифма проницаемости, а на этапе интерпретации результатов выполнялось обратное преобразование к физическим единицам путём применения экспоненты.

Перед началом обучения каждый датасет был разделён на обучающую и валидационную выборки в соотношении 80% на 20%. В процессе обучения применялась оптимизация с использованием алгоритма AdamW при начальной скорости обучения 10^{-4} , размером батча 16 и в течение 20 эпох. В качестве функции потерь использовалась среднеквадратичная ошибка (MSE) между предсказанным и истинным логарифмом проницаемости. Для мониторинга качества модели на валидационной выборке дополнительно отслеживались средняя абсолютная ошибка (MAE) и коэффициент детерминации R^2 .

Архитектура модели включала стандартную иерархическую структуру Swin Transformer с последовательным уменьшением разрешения и увеличением размерности признаков на каждом уровне. После прохождения всех слоёв выходные признаки подвергались глобальному усреднению (Global Average Pooling) и подавались в регрессионный полносвязный слой для предсказания одного скалярного значения. Для повышения обобщающей способности модели использовались функции активации ReLU и слой Dropout. Обучение моделей проводилось с использованием библиотеки PyTorch 1.13.1 на видеокарте NVIDIA Quadro P5000 при поддержке CUDA 11.7. Операционная система — Windows 10, программная среда — Python 3.8.

3. Результаты и обсуждение

3.1. Результаты обучения моделей

Для решения задачи прогнозирования нормированных значений 3D-проницаемости по микротомографическим изображениям были обучены две отдельные модели Swin Transformer: одна на датасете, сформированном с использованием агрегирования проницаемости по гармоническому среднему, другая — на датасете, построенном на основе модели бутылочного горлышка (рис. 4). Обе модели обучались в течение 20 эпох на выборке из 52 327 изображений (41 861 для обучения и 10 466 для валидации).

Модель гармонического среднего показала высокую сходимость и стабильность при обучении, к концу которого значение функции потерь в логарифмической шкале снизилось до 0,0715 на обучающей выборке и 0,1596 на валидационной. Итоговые метрики в лог-пространстве составили: среднеквадратичная ошибка (MSE) — 0,1596, средняя абсолютная ошибка (MAE) — 0,1912, коэффициент детерминации (R^2) — 0,988. Низкие значения ошибок объясняются использованием логарифмического преобразования проницаемости, что позволило сгладить разброс значений и обеспечить устойчивую сходимость модели. В физическом масштабе коэффициент детерминации составил $R^2=0,904$, что свидетельствует о сохранении высокой степени соответствия между прогнозируемыми и измеренными значениями проницаемости.

Модель бутылочного горлышка также продемонстрировала хорошую сходимость и устойчивость обучения достигнув к 20-й эпохе значения функции потерь 0,0474 в логарифмической шкале на обучающей выборке и 0,0642 на валидационной. Основные метрики модели в лог-пространстве достигли: среднеквадратичная ошибка (MSE) — 0,1742, средняя абсолютная ошибка (MAE) — 0,1971, коэффициент детерминации (R^2) — 0,986. Работа в логарифмическом пространстве позволила эффективно стабилизиро-

вать процесс обучения на фоне значительного разброса исходных значений проницаемости. В физическом масштабе коэффициент детерминации составил $R^2 = 0,879$, что также подтверждает способность модели адекватно описывать глобальные закономерности изменения проницаемости вдоль образцов.

Хотя модель с гармоническим средним демонстрирует более низкое значение log-MSE, эта метрика акцентирует внимание на относительных отклонениях от геометрического среднего. В физических единицах агрегация по принципу бутылочного горлышка снижает как MAE, так и RMSE, что указывает на более точное соответствие лабораторной проницаемости по всему динамическому диапазону.




Рис. 4. История обучения моделей Swin: значение функции потерь log-MSE в зависимости от эпохи для случаев с гармоническим средним и бутылочным горлышком

3.2. Результаты тестирования моделей

Точность предсказания проницаемости обученных моделей была дополнительно оценена на тестовой выборке, состоящей из 10 карбонатных образцов, для которых были проведены экспериментальные измерения газопроницаемости (табл. 1). Образцы были предварительно отсняты на микрофотографе, разделены на стеки срезов и подвергнуты предобработке в соответствии с методикой, описанной ранее. Каждому образцу были сопоставлены прогнозируемые значения проницаемости, полученные двумя моделями: моделью, обученной на гармоническом среднем, и моделью бутылочного горлышка.

Таблица 1. Результаты предсказания для десяти новых карбонатных образцов (слепое тестирование): экспериментальные значения газовой проницаемости и предсказания моделей Swin с гармоническим средним и методом бутылочного горлышка

Образец	Экспериментальная газовая проницаемость, $\text{мкм}^2 \times 10^{-3}$	Модель гармонического среднего, $\text{КзD, мкм}^2 \times 10^{-3}$	Модель бутылочного горлышка, $\text{КзD, мкм}^2 \times 10^{-3}$
1	617,9	423,8	762,6
2	9,3	16,3	2,9
3	202,3	159,9	102,7
4	2,1	0,4	0,2
5	53,6	130,7	92,4
6	35,3	21,1	4,6
7	488,6	524,6	915,2
8	2295,2	1485,6	2336,6
9	0,4	0,1	0,2
10	984,9	1454,8	736,2

Для обеих моделей были рассчитаны ключевые метрики качества предсказаний: средняя абсолютная ошибка (MAE) и среднеквадратичная ошибка (RMSE). Расчёт метрик проводился по значениям абсолютных отклонений прогнозируемой проницаемости от экспериментальных данных.

Результаты сравнительного анализа представлены в табл. 2. Средняя абсолютная ошибка для модели, обученной на гармоническом среднем, составила $165,2 \text{ на мкм}^2 \times 10^{-3}$, а для модели бутылочного горлышка — $103,9 \text{ на мкм}^2 \times 10^{-3}$. Среднеквадратичная ошибка для этих моделей составила $303,9 \text{ на мкм}^2 \times 10^{-3}$ и $166,9 \text{ на мкм}^2 \times 10^{-3}$ соответственно. Таким образом, модель бутылочного горлышка показала существенно более высокую точность предсказания: значения MAE и RMSE для неё оказались на 37 % и 45 % ниже, чем для модели на гармоническом среднем.

Следует отметить, что модель бутылочного горлышка обеспечивала более стабильные результаты как для образцов с низкой проницаемостью (например, для образцов 4 и 9), так и для образцов с высокой проницаемостью (образцы 1 и 8). В то время как модель на гармоническом среднем в ряде образцов с высокой проницаемостью демонстрировала значительные отклонения (например, ошибки для образцов 8 и 10 достигали $809,6$ и $469,9 \text{ на мкм}^2 \times 10^{-3}$ соответственно), однако показала достаточно стабильные результаты на образцах с низкой (образцы 2, 4 и 9) и средней проницаемостью (образцы 1, 3 и 7).

Рисунок 5 иллюстрирует посрезовые профили проницаемости, предсказанные двумя моделями для одного и того же карбонатного образца, представленного в Таблице 1 (образец 1). Агрегация по принципу бутылочного горлышка обеспечивает более сглаженный профиль и более точное соответствие лабораторной проницаемости (горизонтальная пунктирная линия), особенно в интервалах с высокой проницаемостью, тогда как предсказания модели с гармоническим средним демонстрируют более выраженные локальные отклонения. Данное визуальное сравнение подтверждает статистическое преимущество модели бутылочного горлышка, обсуждавшееся выше.

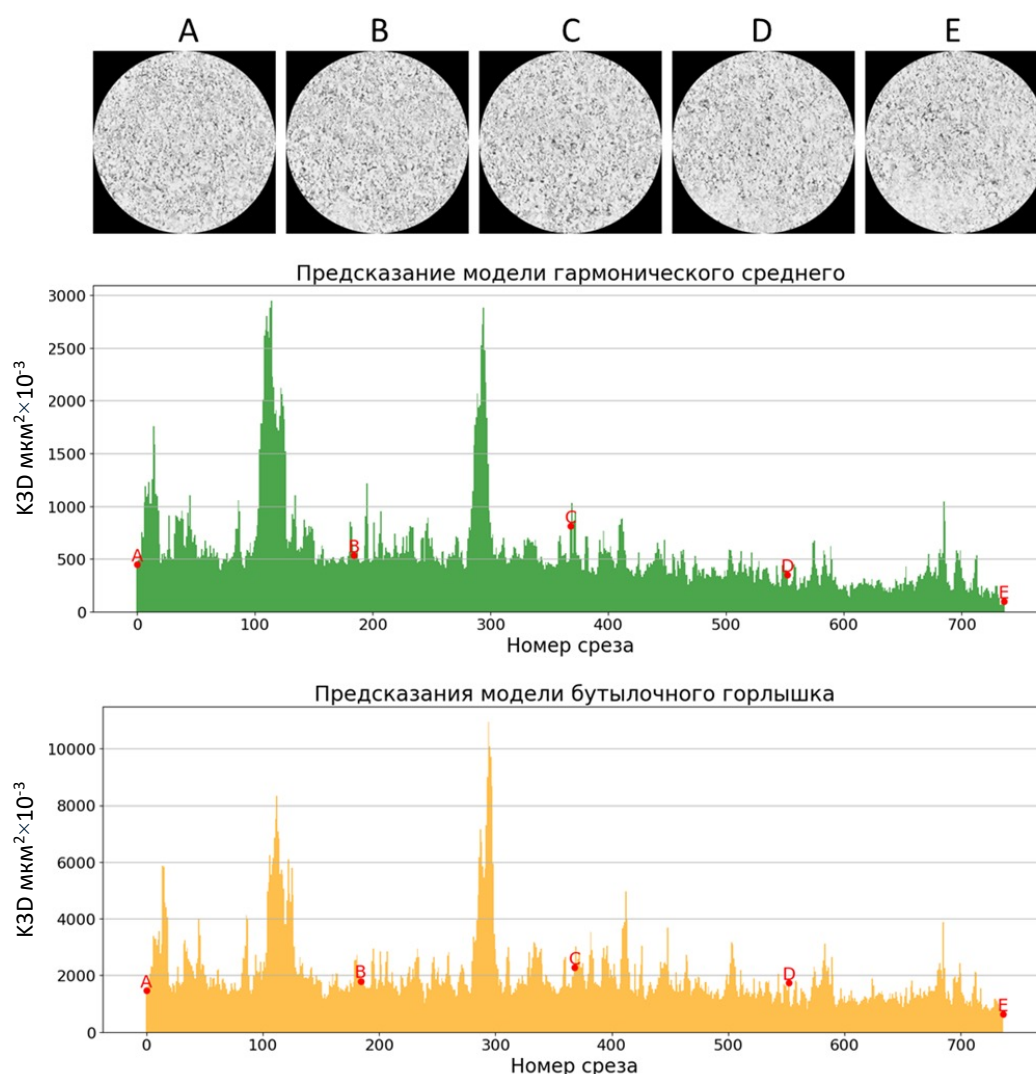


Рис. 5. Посрезовые профили проницаемости, предсказанные моделями с гармоническим средним и бутылочным горлышком для одного карбонатного керна (образец 1 в Таблице 1).

3.3. Обсуждение

Две физически обусловленные модели, разработанные в рамках данного исследования, демонстрируют, что газовую проницаемость можно успешно оценивать по стеку низкоразрешающих микро-КТ-изображений (34,6–36 мкм на воксель) стандартных карбонатных кернов. Благодаря архитектуре Swin Transformer, способной улавливать как субвоксельные текстурные особенности, так и дальнodelствующие связи, модели хорошо обобщаются на гетерогенные многомасштабные структуры, с которыми, как правило, не справляются простые сверточные сети. Предсказание по полному стеку занимает всего несколько секунд, делая расчёт проницаемости незначительным дополнением к цифровому керну и позволяя интегрировать результаты в реальном времени в пайплайны, которые уже выполняют литофациальную классификацию [14], предсказание пористости и другие оценки физических свойств.

Однако этот подход пока не является универсальным. Метки на уровне срезов формируются на основе фрактальной модели Lei и соавт. [22], которая теряет точность, если отдельное изображение содержит очень крупную открытую трещину или каверну, функционирующую как практически неограниченный канал фильтрации. Такие ситуации характерны для плотных карбонатов: один срез может содержать гигантскую пустоту, тогда как соседний — быть практически монолитным и непроницаемым. В ре-

зультате отдельные срезы получают синтетические значения 3D-проницаемости, достигающие либо крайне высоких, либо близких к нулю величин (до 10^5 – 10^6 мкм² × 10^{-3} против $<0,1$ мкм² × 10^{-3}). Такое распределение с тяжёлым хвостом затрудняет сходимость: градиенты размываются за счёт крайних меток, и сеть переобучается на редкие, но масштабно доминирующие срезы. Поскольку проблема связана не с самой сетью, а со схемой разметки, керны с чрезмерно крупными кавернами и трещинами временно исключаются из обучения, чтобы модели работали в пределах диапазона проницаемостей, типичных для большинства карбонатов.

Вторая ограничивающая сторона связана с грубым размером вокселя. Поровые горлышки субвоксельного масштаба размыты, края трещин сглажены, а минимальный радиус поры в формуле приходится задавать искусственно. Нормализация итоговых значений компенсирует смещение среднего, но форма распределения остаётся искажённой, что снижает переносимость сети на изображения с ещё более низким разрешением или на породы, доминирующие микронными каналами.

Третьим ограничением является отсутствие обученного мета-модуля. В текущей реализации предсказания на уровне срезов агрегируются фиксированными физическими формулами и затем пересчитываются по масштабу до лабораторной проницаемости соответствующего стандартного керна. Отказ от такой пост-калибровки в пользу мета-агрегатора устранил бы необходимость ручной настройки коэффициентов, однако доступных на сегодня данных недостаточно для обучения второй нейросети без переобучения.

Сильными сторонами метода являются практически полное отсутствие ручной сегментации при инференсе, малый объём обучающего набора и простота развёртывания на GPU-кластерах. Ключевыми направлениями дальнейшего развития являются более устойчивая обработка сильнотрещиноватых и кавернозных срезов, повышение информативности сканов за счёт более детальных режимов микро-КТ и переход к более крупной модели, способной принимать изображения высокого разрешения, а также расширение разнообразия обучающего набора для последующего обучения мета-агрегатора. Реализация этих шагов позволит превратить предложенный подход из лабораторного прототипа в практический инструмент комплексного анализа цифрового керна.

4. Заключение

Проведённое исследование демонстрирует эффективность подхода физически обусловленного машинного обучения для оценки газовой проницаемости карбонатных коллекторов на основе низкоразрешающих микро-КТ изображений стандартных кернов. Для обучения двух моделей Swin Transformer использовались метки проницаемости, полученные с применением фрактальной аналитической модели и агрегированные с использованием гармонического среднего и подхода бутылочного горлышка.

Результаты показывают, что обе модели способны обеспечивать приближённые, но физически согласованные оценки проницаемости на уровне керна в широком диапазоне значений. Модель с агрегированием по принципу бутылочного горлышка продемонстрировала более высокую общую точность на тестовой выборке как в интервалах низкой, так и высокой проницаемости, что свидетельствует о её большей пригодности для предварительной количественной оценки в условиях сложной гетерогенности.

Модель с гармоническим средним также показала удовлетворительные результаты, особенно для образцов с низкой и средней проницаемостью. Благодаря своей простоте она может быть полезна для экспресс-скрининга или при анализе относительно однородных кернов с умеренной проницаемостью.

Ключевым преимуществом предложенного подхода является возможность выполнять предсказания напрямую по необработанным срезам микро-КТ без необходимости сегментации, 3D-реконструкции или априорной информации о геометрии образца. Это

позволяет существенно сократить затраты времени и ресурсов по сравнению с традиционным анализом керна и при этом сохранить совместимость с существующими цифровыми пайплайнами.

Полученные результаты подтверждают применимость разработанных моделей для первичного скрининга проницаемости в цифровом керновом анализе. Их интеграция в практические рабочие процессы может повысить эффективность начальной стадии изучения коллектора, оптимизировать отбор образцов и стать основой для дальнейшего развития методов прогноза петрофизических свойств на основе изображений. В качестве направлений развития рассматриваются внедрение обучаемого мета-агрегатора и расширение обучающего набора за счёт включения более сложных поровых систем, включая высокотрещиноватые и кавернозные карбонаты.

Благодарности

Работа выполнена за счет гранта Академии наук Республики Татарстан, предоставленного молодым кандидатам наук (постдокторантам) с целью защиты докторской диссертации, выполнения научно-исследовательских работ, а также выполнения трудовых функций в научных и образовательных организациях Республики Татарстан в рамках Государственной программы Республики Татарстан «Научно-технологическое развитие Республики Татарстан» (соглашение № 20/2024-ПД).

Список литературы

1. Tembely M., AlSumaiti A.M., Alameri W.S. Machine and deep learning for estimating the permeability of complex carbonate rock from X-ray micro-computed tomography // *Energy Reports*. 2021. Vol. 7. P. 1460–1472.
2. Wu H.Y. et al. Deep learning in the advanced core sample porosity determination with XCT image // *Earth Science Informatics*. 2025. Vol. 18, № 1. P. 17.
3. Kadyrov R., Statsenko E., Galiullin B. The porous space structure of Domanik shales in the east of Russian plate // *International Multidisciplinary Scientific Geoconference SGEM*. 2018. Vol. 18, № 1.4. P. 907–914.
4. Zhang H. et al. Influence of heterogeneity on carbonate permeability upscaling: a renormalization approach coupled with the pore network model // *Energy & Fuels*. 2022. Vol. 36, № 6. P. 3003–3015.
5. Karimpouli S., Tahmasebi P. Image-based velocity estimation of rock using convolutional neural networks // *Neural Networks*. 2019. Vol. 111. P. 89–97.
6. Karimpouli S., Kadyrov R. Multistep super-resolution Double-U-Net (SRDUN) for enhancing the resolution of Berea sandstone images // *Journal of Petroleum Science & Engineering*. 2022. Vol. 216. P. 110833.
7. McPhee C., Reed J., Zubizarreta I. *Core Analysis: A Best Practice Guide*. Developments in Petroleum Science. Vol. 64. 1st ed. Elsevier, 2015. 852 p.
8. Niya S.M.R., Selvadurai A.P.S. A statistical correlation between permeability, porosity, tortuosity and conductance // *Transport in Porous Media*. 2018. Vol. 121, № 3. P. 741–752.
9. Costa A. Permeability-porosity relationship: a re-examination of the Kozeny–Carman equation based on a fractal pore-space geometry assumption // *Geophysical Research Letters*. 2006. Vol. 33, № 2. L02318.
10. Xu P., Yu B. Developing a new form of permeability and Kozeny–Carman constant for homogeneous porous media by means of fractal geometry // *Advances in Water Resources*. 2008. Vol. 31, № 1. P. 74–81.
11. Saxena N. et al. Estimating permeability from thin sections without reconstruction: digital rock study of 3D properties from 2D images // *Computers & Geosciences*. 2017. Vol. 102. P. 79–99.

12. Karimpouli S. et al. Applicability of 2D algorithms for 3D characterization in digital rock physics: an example of a machine-learning-based super-resolution image generation // *Acta Geophysica*. 2024. Vol. 72, № 2. P. 861–874.
13. Kadyrov R.I. Multiple cubes growth algorithms for simple representative elementary volume determination on 3D binary images // *Scientific Visualization*. 2024. Vol. 16, № 1. P. 124–135.
14. Kadyrov R., Statsenko E., Nguyen T.H. Integrating μ CT imaging of core plugs and transfer learning for automated reservoir rock characterization and tomofacies identification // *Marine & Petroleum Geology*. 2024. Vol. 168. P. 107014.
15. Zhang H. et al. Permeability prediction of low-resolution porous-media images using an autoencoder-based convolutional neural network // *Journal of Petroleum Science & Engineering*. 2022. Vol. 208. P. 109589.
16. Araya-Polo M. et al. Deep-learning-driven permeability estimation from 2D images // *Computational Geosciences*. 2020. Vol. 24, № 2. P. 571–580.
17. Wu J., Yin X., Xiao H. Seeing permeability from images: fast prediction with convolutional neural networks // *Science Bulletin*. 2018. Vol. 63, № 18. P. 1215–1222.
18. Alqahtani N. et al. Machine learning for predicting properties of porous media from 2D X-ray images // *Journal of Petroleum Science & Engineering*. 2020. Vol. 184. P. 106514.
19. Alqahtani N., Armstrong R.T., Mostaghimi P. Deep-learning convolutional neural networks to predict porous-media properties // *SPE Asia Pacific Oil & Gas Conference and Exhibition (APOGCE)*. Kuala Lumpur, 2018. Paper SPE-191493-MS.
20. Tembely M., AlSumaiti A. Deep learning for fast and accurate prediction of complex carbonate rock permeability from 3D micro-CT images // *Abu Dhabi International Petroleum Exhibition & Conference (ADIPEC)*. Abu Dhabi, 2019. Paper SPE-197457-MS.
21. Kalule R. et al. Stacked ensemble machine learning for porosity and absolute-permeability prediction of carbonate rock plugs // *Scientific Reports*. 2023. Vol. 13, № 1. P. 9855.
22. Lei G. et al. Estimating permeability of porous media from 2D digital images // *Journal of Marine Science & Engineering*. 2023. Vol. 11, № 8. P. 1614.
23. Meyer F. Topographic distance and watershed lines // *Signal Processing*. 1994. Vol. 38, № 1. P. 113–125.
24. Kadyrov R.I., Zakirov T.R. 2D fractal and multifractal analysis of porous space in carbonate oil reservoir // *Neftyanoye Khozyaystvo – Oil Industry*. 2016. № 11. P. 72–74.
25. Baek S.H. et al. X-ray computed micro-tomography imaging of abiotic carbonate precipitation in porous media from a supersaturated solution: insights into effect of CO₂ mineral trapping on permeability // *Water Resources Research*. 2019. Vol. 55, № 5. P. 3835–3855.
26. Bouchard J. et al. Terahertz imaging for non-destructive porosity measurements of carbonate rocks // *Scientific Reports*. 2022. Vol. 12, № 1. P. 18018.
27. Liu Z. et al. Swin Transformer: hierarchical vision transformer using shifted windows // *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2021. P. 9992–10002.

Physics-Guided Machine Learning for Predicting Gas Permeability of Standard Carbonate Core Plugs from Low-Resolution Microtomography Image Stacks

R. I. Kadyrov¹, T. H. Nguyen², E. O. Statsenko³
Kazan Federal University (Institute of Geology and Petroleum Technologies),
Kazan, Russia

¹ ORCID: 0000-0002-7566-6312, rail7777@gmail.com

² ORCID: 0000-0001-6155-9017, thanhtu154@gmail.com

³ ORCID: 0000-0001-6259-1713, e.statsenko@yahoo.com

Abstract

This study presents a physics-guided workflow for predicting the gas permeability of carbonate reservoirs directly from low-resolution microtomography (μ CT) imagery. Standard core plugs were scanned at 34.6–36 $\mu\text{m}/\text{voxel}$, and a total of 52,327 grayscale d aggregation against experimental plug-scale measurements. The grayscale images and log-transformed permeability labels were used to train a Swin Transformer model, pre-trained on ImageNet. Two models were developed independently: one using harmonic-mean aggregation and the other using the bottleneck approach. Both models demonstrate stable convergence despite the highly skewed data distribution. The harmonic-mean model achieved $R^2 = 0.904$ on the validation set, while the bottleneck model yielded $R^2 = 0.879$. Although the higher R^2 reflects a closer fit to the overall trend, the bottleneck model, in blind testing on ten independent samples ($0.4\text{--}2300 \mu\text{m}^2 \times 10^{-3}$), reduced the MAE from 165 to 104 $\mu\text{m}^2 \times 10^{-3}$ (–37 %) and the RMSE from 255 to 140 $\mu\text{m}^2 \times 10^{-3}$ (–45 %) relative to the harmonic-mean model. The method provides a fast and interpretable permeability prediction based solely on raw μ CT slices, without requiring image segmentation or 3D reconstruction. The proposed approach demonstrates robust performance across a wide range of standard carbonate plugs and effectively captures permeability trends even in the presence of structural heterogeneity. While samples with extremely large fractures or vugs can introduce local inconsistencies in labelling due to the limitations of slice-based estimation, these cases are rare and can be systematically addressed in future work. Overall, the results highlight the strong potential of physics-guided machine learning to accelerate digital core analysis and provide reliable, image-driven permeability predictions for complex carbonate reservoirs.

Keywords: permeability, carbonates, μ CT, digital core, porous structure, standard core plug, physics-guided machine learning, 2D image analysis.

References

1. Tembely M., AlSumaiti A.M., Alameri W.S. Machine and deep learning for estimating the permeability of complex carbonate rock from X-ray micro-computed tomography // *Energy Reports*. 2021. Vol. 7. P. 1460–1472.
2. Wu H.Y. et al. Deep learning in the advanced core sample porosity determination with XCT image // *Earth Science Informatics*. 2025. Vol. 18, № 1. P. 17.
3. Kadyrov R., Statsenko E., Galiullin B. The porous space structure of Domanik shales in the east of Russian plate // *International Multidisciplinary Scientific Geoconference SGEM*. 2018. Vol. 18, № 1.4. P. 907–914.
4. Zhang H. et al. Influence of heterogeneity on carbonate permeability upscaling: a renormalization approach coupled with the pore network model // *Energy & Fuels*. 2022. Vol. 36, № 6. P. 3003–3015.

5. Karimpouli S., Tahmasebi P. Image-based velocity estimation of rock using convolutional neural networks // *Neural Networks*. 2019. Vol. 111. P. 89–97.
6. Karimpouli S., Kadyrov R. Multistep super-resolution Double-U-Net (SRDUN) for enhancing the resolution of Berea sandstone images // *Journal of Petroleum Science & Engineering*. 2022. Vol. 216. P. 110833.
7. McPhee C., Reed J., Zubizarreta I. *Core Analysis: A Best Practice Guide*. Developments in Petroleum Science. Vol. 64. 1st ed. Elsevier, 2015. 852 p.
8. Niya S.M.R., Selvadurai A.P.S. A statistical correlation between permeability, porosity, tortuosity and conductance // *Transport in Porous Media*. 2018. Vol. 121, № 3. P. 741–752.
9. Costa A. Permeability-porosity relationship: a re-examination of the Kozeny–Carman equation based on a fractal pore-space geometry assumption // *Geophysical Research Letters*. 2006. Vol. 33, № 2. L02318.
10. Xu P., Yu B. Developing a new form of permeability and Kozeny–Carman constant for homogeneous porous media by means of fractal geometry // *Advances in Water Resources*. 2008. Vol. 31, № 1. P. 74–81.
11. Saxena N. et al. Estimating permeability from thin sections without reconstruction: digital rock study of 3D properties from 2D images // *Computers & Geosciences*. 2017. Vol. 102. P. 79–99.
12. Karimpouli S. et al. Applicability of 2D algorithms for 3D characterization in digital rock physics: an example of a machine-learning-based super-resolution image generation // *Acta Geophysica*. 2024. Vol. 72, № 2. P. 861–874.
13. Kadyrov R.I. Multiple cubes growth algorithms for simple representative elementary volume determination on 3D binary images // *Scientific Visualization*. 2024. Vol. 16, № 1. P. 124–135.
14. Kadyrov R., Statsenko E., Nguyen T.H. Integrating μ CT imaging of core plugs and transfer learning for automated reservoir rock characterization and tomofacies identification // *Marine & Petroleum Geology*. 2024. Vol. 168. P. 107014.
15. Zhang H. et al. Permeability prediction of low-resolution porous-media images using an autoencoder-based convolutional neural network // *Journal of Petroleum Science & Engineering*. 2022. Vol. 208. P. 109589.
16. Araya-Polo M. et al. Deep-learning-driven permeability estimation from 2D images // *Computational Geosciences*. 2020. Vol. 24, № 2. P. 571–580.
17. Wu J., Yin X., Xiao H. Seeing permeability from images: fast prediction with convolutional neural networks // *Science Bulletin*. 2018. Vol. 63, № 18. P. 1215–1222.
18. Alqahtani N. et al. Machine learning for predicting properties of porous media from 2D X-ray images // *Journal of Petroleum Science & Engineering*. 2020. Vol. 184. P. 106514.
19. Alqahtani N., Armstrong R.T., Mostaghimi P. Deep-learning convolutional neural networks to predict porous-media properties // *SPE Asia Pacific Oil & Gas Conference and Exhibition (APOGCE)*. Kuala Lumpur, 2018. Paper SPE-191493-MS.
20. Tembely M., AlSumaiti A. Deep learning for fast and accurate prediction of complex carbonate rock permeability from 3D micro-CT images // *Abu Dhabi International Petroleum Exhibition & Conference (ADIPEC)*. Abu Dhabi, 2019. Paper SPE-197457-MS.
21. Kalule R. et al. Stacked ensemble machine learning for porosity and absolute-permeability prediction of carbonate rock plugs // *Scientific Reports*. 2023. Vol. 13, № 1. P. 9855.
22. Lei G. et al. Estimating permeability of porous media from 2D digital images // *Journal of Marine Science & Engineering*. 2023. Vol. 11, № 8. P. 1614.
23. Meyer F. Topographic distance and watershed lines // *Signal Processing*. 1994. Vol. 38, № 1. P. 113–125.
24. Kadyrov R.I., Zakirov T.R. 2D fractal and multifractal analysis of porous space in carbonate oil reservoir // *Neftyanoye Khozyaystvo – Oil Industry*. 2016. № 11. P. 72–74.

25. Baek S.H. et al. X-ray computed micro-tomography imaging of abiotic carbonate precipitation in porous media from a supersaturated solution: insights into effect of CO₂ mineral trapping on permeability // *Water Resources Research*. 2019. Vol. 55, № 5. P. 3835–3855.
26. Bouchard J. et al. Terahertz imaging for non-destructive porosity measurements of carbonate rocks // *Scientific Reports*. 2022. Vol. 12, № 1. P. 18018.
27. Liu Z. et al. Swin Transformer: hierarchical vision transformer using shifted windows // *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2021. P. 9992–10002.