

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ АНАЛИЗА ИЗОБРАЖЕНИЙ УЧАСТКОВ ШЛИФОВ КВАРЦЕВОГО ПЕСЧАНИКА С КАРБОНАТНЫМ ЦЕМЕНТОМ

Р. Ф. Ахметов^{1,*} , Т. А. Муртазин¹ , В. П. Морозов¹ , Д. Н. Тумаков¹ ,
В. А. Судаков¹ , Д. К. Нургалиев¹ , З. Д. Каюмов² 

¹Казанский федеральный университет, Казань, Российская Федерация

²ООО «Геопай», Казань, Российская Федерация

***Контакт:** Радик Фанусович Ахметов, ahmetov.radi@mail.ru

Аннотация: Петрографический анализ шлифов терригенных пород играет ключевую роль в изучении характеристик коллекторов, позволяя оценивать текстурно-структурные особенности и пористость, что необходимо для реконструкции условий осадконакопления и постседиментационных преобразований. Традиционный ручной анализ шлифов является трудоёмким и субъективным, что обуславливает необходимость его автоматизации. В настоящей работе предложен метод автоматизированного анализа участков шлифов песчаника с карбонатным цементом на основе глубокого обучения, сочетающий экзemplярную сегментацию с использованием модели Mask R-CNN и семантическую сегментацию с применением SemanticFPN. Такой ансамблевый подход обеспечивает высокую точность сегментации, подтверждённую метриками Pixel Accuracy и IoU, и позволяет значительно ускорить обработку петрографических данных, повысить их объективность и воспроизводимость, что представляет практическую ценность для геологических и нефтегазовых исследований.

Ключевые слова: петрографический шлиф, сегментация зёрен минералов, петрография осадочных пород, глубокое обучение, искусственный интеллект

Цитирование: Ахметов Р. Ф., Муртазин Т. А., Морозов В. П., Тумаков Д. Н., Судаков В. А., Нургалиев Д. К., and Каюмов З. Д. Применение нейронных сетей для анализа изображений участков шлифов кварцевого песчаника с карбонатным цементом // Russian Journal of Earth Sciences. — 2026. — Т. 26. — ES3014. — DOI: 10.2205/2026es001103 — EDN: BXIYSD

1. Введение

В геологической науке существует множество методов исследования характеристик пород-коллекторов. Одним из наиболее ценных и широко применяемых методов является оптическая микроскопия — петрографический анализ шлифов, изготовленных из представительных образцов керна. Петрографический шлиф — это тонкая пластинка горной породы, имеющая толщину в пределах 0,02–0,03 мм, изготовленная для изучения породы с помощью микроскопа. Петрографический анализ шлифов служит ключевым инструментом для глубокого понимания микроструктуры и микротекстуры пород. Изучение шлифов позволяет делать выводы о геологическом строении, условиях образования осадочных отложений и определении коллекторских свойств пород.

Традиционно петрографический анализ шлифов требует визуального осмотра под микроскопом. Это может быть сложной задачей, учитывая разнообразие и уникальность оптических свойств минералов [Kerr, 1977]. Однако с развитием компьютерных технологий появились новые, более передовые методы анализа. Например, в работе [Dabek et al., 2023] ранее был предложен метод сегментации зёрен, основанный на компьютерном анализе микроскопических изображений. Этот метод сочетает в себе автоматизированный и неавтоматизированный подходы, предоставляя точное решение

RESEARCH ARTICLE

<https://elibrary.ru/BXIYSD>

Получено: 14 октября 2025 г.

Принято: 9 февраля 2026 г.

Опубликовано: 28 августа 2026 г.



© 2026. Коллектив авторов.

для сегментации минералов в породных срезах. Имеется также метод многозадачного распознавания изображений с использованием Faster R-CNN (Faster Region-based Convolutional Neural Network) [Wang et al., 2023], который особенно эффективен для определения оолитовой структуры. Эти исследования подчеркивают важность оптических свойств минерального состава, структуры и текстуры в шлифах пород для идентификации пород и их анализа.

В работе [González-Vargas and Gutiérrez-Castorena, 2022] был предложен новый метод классификации степеней преобразования органического вещества в шлифах посредством значений яркости.

В исследовании [Su et al., 2020] был предложен метод Con-CNN для классификации пород на основе изображений шлифов. Эксперименты показали, что метод Con-CNN (Concatenated Convolutional Neural Network) может эффективно извлекать особенности изображений шлифов и устанавливать соответствие между изображением конкретного типа породы и его основными характеристиками на основе обучения по образцам.

В работе [Leichter et al., 2022] использовались свёрточные нейронные сети для характеристики шлифов вулканических пород. Было показано, что модель DeepLabV3, предназначенная для сегментации RGB-изображений, может быть использована для сегментации изображений, полученных с помощью обратно рассеянных электронов шлифов вулканических пород, состоящих из фенокристаллов и микрокристаллической матрицы.

В одной из работ [Dell'Aversana, 2023] акцентировано внимание на применении различных типов нейронных сетей для автоматической классификации изображений минералов, особо выделяя преимущества ResNets (Residual Neural Network).

Современные технологии, особенно методы машинного обучения, предоставляют геологам новые и более эффективные инструменты для анализа и исследования пород, обогащая наше понимание их структуры и свойств.

В настоящем исследовании представлен алгоритм, предназначенный для автоматизации анализа изображений петрографических шлифов кварцевого песчаника с карбонатным цементом. Изображения шлифов получены в режиме поляризованного света, при увеличении, обеспечивающие высокое качество изображения. Каждый шлиф сфотографирован под различными углами в диапазоне от 0 до 90° с шагом поворота 5°. Полученные изображения подвергнуты аугментации, чтобы увеличить обучающую выборку. При обучении нейронной сети архитектуры Mask R-CNN (Mask Region-based Convolutional Neural Network) применён метод трансферного обучения, при этом начальные веса получены на большом объёме негеологических изображений [Caeser et al., 2018; Lin et al., 2014].

2. Объект исследования

Материалом для обучения нейронной сети послужили шлифы песчаника с кальцитовым цементом (5 шлифов: 10 участков шлифа для обучения, 5 участков для тестирования) пашийского горизонта верхнего девона эльфельско-франского терригенного нефтегазоносного комплекса Южно-Татарского свода, представительные образцы были отобраны из керна Ромашкинского и Ново-Елховского месторождений [Муслимов и др., 2007] (рис. 1). Названный горизонт является основным объектом нефтедобычи на территории Южно-Татарского свода [Данилова, 2008].

3. Цели и задачи

Целью настоящей работы является исследование и разработка метода автоматизированного анализа участков шлифов кварцевого песчаника с карбонатным цементом с применением нейронных сетей. Карбонатный песчаник — это осадочная горная порода, обладающая сложной микроструктурой и разнообразными минеральными составами [Гмид, 2006; Рыкус, 2020], что делает его анализ важным в геологии и нефтяной промышленности.




Рис. 1. Карта расположения Ромашкинского и Ново-Елховского месторождений.

Задачи и этапы исследования:


1. Сбор и предобработка данных. Необходимо собрать наборы изображений участков шлифов песчаника. Для каждого участка требуется иметь качественную разметку границ анализируемых классов минералов.
2. Разработка архитектуры нейронной сети для сегментации участков шлифов. Обучение нейронной сети.
3. Оценка результатов. Проведение экспериментов для оценки качества разработанной модели нейронной сети на тестовых данных.

Ожидаемый результат (рис. 2): разработка эффективного метода автоматизированного анализа участков шлифов кварцевого песчаника с карбонатным цементом с использованием нейронных сетей.

Изображения шлифа в поляризованном свете



В проходящем свете



Результат сегментации




Рис. 2. Ожидаемый результат.

4. Сбор и подготовка данных

Исходными данными послужили цифровые изображения петрографических шлифов, полученные на поляризационном оптическом микроскопе «Axio Imager» (Carl Zeiss, Германия) с одним николем и со скрещенными николями. Изображения шлифа в поляризованном свете получаются при углах поворота микроскопической ступени 0° , 5° , 10° , ..., 90° . Во время вращения столика микроскопа часть зёрен становится светлее, а другая часть, наоборот, темнеет, что связано с изменением их интерференционной окраски [Морозов, 2012]. В результате получается 19 изображений одной области шлифа.

Определение точного центра вращения имеет решающее значение для анализа всего изображения, точной идентификации границ зерна и формы. Процесс объединения микроскопических изображений под разными углами может помочь получить более точные результаты сегментации, чем при использовании одного поляризованного изображения. Результат приведения изображений к общей системе координат и наложения изображений друг на друга (позлементное объединение пикселей с выбором максимального значения) приведён на рис. 3.




Рис. 3. Примеры изображений в поляризованном свете при различных углах поворота столика микроскопа (0° , 30° , 60°) и результат объединения изображений, приведённых к общей системе координат.

Также изображения, приведённые к общей системе координат, переводятся в градации серого и формируют трёхканальное изображение со следующими значениями для каждого канала RGB (Red, Green, Blue): изображения шлифов под углами 0° , 30° и 60° соответственно. Выбор именно трёхканального представления обусловлен тем, что изображения, полученные при различных углах поворота столика микроскопа, содержат комплементарную информацию о микроструктуре породы: одни и те же зёрна и их границы проявляются с разной контрастностью и интенсивностью в зависимости от ориентации кристаллов и их оптических свойств. Использование одного канала с максимальной контрастностью может приводить к потере зависимой от угла наблюдения части информации.

Таким образом, трёхканальное изображение в данной работе используется не как стандартное цветное представление, а как способ объединения информативных признаков, полученных при различных условиях наблюдения. Отметим, что в полученном изображении границы рассматриваемых зёрен выражены более чётко по сравнению

с одиночными поляризованными изображениями, поэтому в качестве входных данных для модели нейронной сети используется трёхканальное изображение. Данный подход позволяет модели более точно распознавать границы карбонатного вещества в кварцевом песчанике.

Истинная маска для обучения и тестирования нейронной сети формировалась на основе ручной разметки изображений шлифов. Разметка выполнялась экспертно на цифровых изображениях шлифов с выделением пиксельных областей, соответствующих основным минеральным фазам (кварц, карбонатные минералы) и границам зёрен. Полученные вручную сегментационные маски использовались в качестве эталонных при обучении модели и оценке качества сегментации.

Нейронным сетям требуется много обучающих данных для получения хороших результатов и предотвращения переобучения. В связи с относительно малым количеством размеченных данных реализуется искусственное увеличение размеченной выборки данных с помощью аугментации. Аугментация изображений — это процесс создания новых обучающих примеров из существующих. Данный метод позволил улучшить качество прогнозирования модели на тестовых изображениях.

В данной работе используются такие методы аугментации, как повороты, сдвиги и изменение масштаба изображений (рис. 4б, в, г). Также на рис. 4 показана ручная разметка зёрен кварца, карбонатных минералов и их границ (рис. 4а).




Рис. 4. Процесс аугментации данных.

Во избежание формирования нефизичных изображений параметры аугментации были ограничены. Сдвиги и масштабирование выполнялись в пределах $\pm 20\%$ от исходного размера изображения, что позволяет сохранить геометрическую целостность зёрен и характер границ между минеральными фазами. Используемые преобразования не изменяют внутреннюю микроструктуру породы и не искажают физически значимые признаки, а лишь моделируют допустимые вариации положения и масштаба наблюдаемых объектов.

5. Архитектура нейронной сети

5.1. Сегментация изображений

В настоящее время наиболее эффективными методами сегментации изображений являются методы на основе глубокого обучения. Они основаны на использовании свёрточных нейронных сетей (CNN), которые позволяют автоматически извлекать признаки из изображений и классифицировать каждый пиксель в изображении как часть определённого класса. Рассмотрим три основных типа сегментации на основе глубокого обучения:

1. Семантическая сегментация — это задача классификации каждого пикселя изображения в соответствии с классом объекта, к которому он относится. В результате каждый пиксель получает метку класса, и объекты на изображении разделяются

по классам. Для решения этой задачи на основе глубокого обучения применяются свёрточные нейронные сети (CNN), которые способны обрабатывать изображения с высокой точностью и скоростью. Архитектуры CNN, используемые для семантической сегментации, обычно основаны на энкодер-декодер модели, где входное изображение постепенно уменьшается до меньших размеров с помощью свёрточных слоев, а затем восстанавливается до оригинального размера с помощью операций транспонированной свёртки.

2. Экземплярная сегментация изображений — это задача компьютерного зрения, которая заключается в выделении и классификации индивидуальных объектов на изображении с точностью до пикселя. В отличие от семантической сегментации, где каждому пикселю присваивается общий класс, в экземплярной сегментации каждый объект размечается как отдельный экземпляр с уникальным идентификатором.
3. Паноптическая сегментация. Паноптическая сегментация сочетает в себе оба предыдущих типа сегментации: она идентифицирует объекты по меткам классов, а также идентифицирует все экземпляры в данном изображении.

5.2. Mask R-CNN

В экземплярной сегментации каждый пиксель на изображении маркируется как принадлежащий к конкретному объекту, и каждый объект имеет свой уникальный идентификатор. Таким образом, экземплярная сегментация позволяет различать не только классы, но и конкретные экземпляры объектов (зёрна минералов).

Существует множество методов для решения данной задачи, но одним из популярных является Mask R-CNN [He et al., 2017]. Mask R-CNN — это метод экземплярной сегментации на основе глубокого обучения, который был разработан компанией Facebook в 2017 году. Mask R-CNN является расширением метода R-CNN, который был разработан в 2014 году, и использует свёрточные нейронные сети для выделения объектов на изображении. Mask R-CNN расширяет этот подход, добавляя сегментацию на уровне пикселей для выделения конкретных экземпляров объектов.

Mask R-CNN работает в два этапа. На первом этапе сеть Faster R-CNN [Ren et al., 2017] выделяет области изображения, содержащие объекты, а также классифицирует их по категориям. Затем на втором этапе применяется дополнительная ветвь сети для создания масок, которые отображают форму каждого объекта. Это позволяет точно выделить каждый экземпляр объекта на изображении.

Более подробно процесс работы Mask R-CNN можно описать следующим образом:

1. Выделение регионов (Region Proposal Network, RPN). На этом этапе используется сеть Faster R-CNN, которая выделяет области изображения, где возможно находится объект. RPN предлагает несколько прямоугольных областей, называемых регионами, которые содержат объекты на изображении.
2. Классификация объектов. На этом этапе сеть Faster R-CNN классифицирует объекты, находящиеся в каждом из регионов, на основе обучающих данных. Классификация позволяет определить, какие объекты присутствуют на изображении и какой класс им соответствует.
3. Генерация масок. На этом этапе используется отдельная ветвь нейронной сети для создания масок для каждого экземпляра объекта на изображении. Маска отображает форму каждого объекта, пиксель, который принадлежит объекту, помечается единицей, а все остальные пиксели помечаются нулями.
4. Объединение масок. На этом этапе маски, созданные на предыдущем шаге, объединяются, чтобы получить итоговую сегментацию экземпляров объектов на изображении.

На рис. 5 и 6 приведены результаты сегментации для кварцевых и карбонатных песчаников соответственно.

На рис. 6 видно, что есть значительные расхождения между предсказанной и истинной маской участка шлифа.




Рис. 5. Результат сегментации кварцевых песчаников (Mask R-CNN).




Рис. 6. Результат сегментации карбонатных песчаников (Mask R-CNN).

5.3. Улучшение архитектуры: *Semantic FPN* и *PointRend*

Рассмотрим подход, позволяющий учесть особенности сегментации областей песчаника и повысить качество распознавания.

Основная цель улучшения заключается в создании алгоритма, способного одинаково хорошо работать на изображениях кварцевых песчаников как без, так и с карбонатным цементом. Одной из особенностей шлифов карбонатного песчаника является наличие таких областей, в которых плохо выражены границы карбонатов. Экземплярная сегментация Mask R-CNN на основе трёхканального изображения RGB (каждый канал которого содержит поляризованное изображение шлифа в градациях серого под углами 0° , 30° и 60°) может пропускать и ошибочно добавлять некоторые области карбонатных минералов, что приводит к некорректному подсчету процентного содержания минеральных зёрен. С целью повышения точности прогноза существующей модели Mask R-CNN на исследуемых песчаниках была добавлена и обучена новая модель (SemanticFPN + PointRend) [Kirillov et al., 2019, 2020], решающая задачу семантической сегментации карбонатов и кварца. Модель принимает на вход результаты объединения изображений при скрещённых николях под различными углами съёмки.

FPN (Feature Pyramid Network) — функциональная пирамидальная сеть — представляет собой экстрактор признаков, который берет исходное изображение произвольного размера в качестве входных данных и выводит карты признаков пропорционального размера на нескольких уровнях полностью свёрточным способом. Этот процесс не зависит от базовых свёрточных архитектур. Таким образом, он действует как универсальное решение для построения пирамид признаков внутри глубоких свёрточных сетей для использования в таких задачах, как обнаружение и сегментация объектов. Строительство пирамиды включает в себя путь «снизу вверх» и путь «сверху вниз». Путь «сверху вниз» начинается с самого глубокого слоя сети и постепенно увеличивает его дискретизацию, добавляя преобразованные версии функций с более

высоким разрешением из пути «снизу вверх». FPN создает пирамиду, обычно с масштабом разрешения от $1/32$ до $1/4$, где каждый уровень пирамиды имеет одинаковую размерность канала (по умолчанию 256).

Задача паноптической сегментации объединяет задачи сегментации экземпляров и семантической сегментации. Panoptic Feature Pyramid Networks (Panoptic FPN) стремится унифицировать эти методы на архитектурном уровне, создавая единую сеть для обеих задач. Архитектура сети представлена на рис. 7.




Рис. 7. Архитектура сети Panoptic FPN.

Рассмотрим ветвь для семантической сегментации изображений (рис. 8) — Semantic FPN. Начиная с самого глубокого уровня FPN (в масштабе $1/32$), выполняются три этапа повышения частоты дискретизации для получения карты признаков в масштабе $1/4$, где каждый этап повышения частоты дискретизации состоит из свёртки 3×3 , нормализации, ReLU и двух билинейных операций повышения частоты дискретизации. Эта стратегия повторяется для масштабов FPN $1/16$, $1/8$ и $1/4$.

Результатом является набор карт объектов в одном и том же масштабе $1/4$, которые затем суммируются по элементам. Окончательная свёртка 1×1 , 4-кратная билинейная повышающая дискретизация и softmax используются для создания меток классов для каждого пикселя при исходном разрешении изображения.




Рис. 8. Ветвь для семантической сегментации.

Для улучшения качества выделения границ объектов архитектурой Semantic FPN дополнительно применяется модуль нейронной сети PointRender (рендеринг на основе точек). Это модуль, который выполняет прогнозы сегментации на основе точек

в локально выбранных областях на основе алгоритма итеративного подразделения. PointRend можно гибко применять к задачам сегментации, опираясь на существующие современные модели. Этот модуль выводит чёткие границы объектов в областях, которые были чрезмерно сглажены предыдущими методами.

Перейдем к следующему этапу предлагаемого алгоритма. Дополнительно была обучена еще одна модель экземплярной сегментации Mask R-CNN на изображениях шлифов в проходящем свете, направленная на определение рудных минералов. Конечная маска сегментации рассчитывается путем объединения результатов сегментации (ансамблирование) трёх моделей. Этот подход позволил существенно увеличить точность предсказания рудных и карбонатных минералов с нечётко выраженными границами.

Обновленная схема работы алгоритма для задачи сегментации изображений шлифов (рис. 9) состоит из следующих основных частей:

- Модель №1: экземплярная сегментация Mask R-CNN трёхканального изображения.
- Модель №2: семантическая сегментация Semantic FPN результата объединения изображений в поляризованном свете.
- Модель №3: экземплярная сегментация Mask R-CNN изображения в проходящем свете.
- Объединение результатов сегментации обученных моделей.
- Вычисление процентного содержания минералов по итоговой маске, а параметры зёрен рассчитываются по результатам экземплярной сегментации модели №1.




Рис. 9. Схема сегментации изображений шлифов кварцевого песка с карбонатным цементом.

6. Метрики оценки качества сегментации

Pixel Accuracy, также известная как пиксельная точность, является метрикой для оценки качества классификации или сегментации в задачах компьютерного зрения, таких как обработка изображений или анализ видео. Эта метрика оценивает, насколько точно модель классифицирует или сегментирует каждый пиксель изображения.

В контексте сегментации изображений, где требуется классифицировать каждый пиксель изображения на определённый класс или категорию, пиксельная точность измеряет количество пикселей, которые были правильно классифицированы (верно сегментированы) по отношению ко всем пикселям в изображении. Формула для вычисления пиксельной точности выглядит следующим образом:

$$\text{PixelAccuracy} = \frac{\text{Number of Correctly Classified Pixels}}{\text{Total Number of Pixels}},$$

где Number of Correctly Classified Pixels — количество пикселей, которые были правильно классифицированы моделью; Total Number of Pixels — общее количество пикселей в изображении.

Intersection over Union (IoU) — популярная метрика для оценки качества моделей сегментации в задачах компьютерного зрения [Gadhiya and Kalani, 2021; Padilla et al., 2020]. Она измеряет сходство между предсказанными сегментированными областями и истинными (ожидаемыми) сегментированными областями на изображении.

Формула для вычисления IoU выглядит следующим образом:

$$\text{IoU} = \frac{\text{Intersection Area}}{\text{Union Area}},$$

где Intersection Area — площадь области пересечения между предсказанными и истинными сегментированными областями; Union Area — площадь объединения между предсказанными и истинными сегментированными областями.

IoU оценивает, насколько точно модель сегментирует объекты на изображении. Значение IoU может быть в диапазоне от 0 до 1, где 0 означает полное несходство (нет пересечения) между предсказанной и истинной сегментацией, а 1 означает идеальное совпадение. Метрика IoU используется для каждого класса отдельно, и затем вычисляется средний IoU по всем классам.

7. Результаты сегментации и их количественная оценка

На рис. 10 приведено сравнение результатов сегментации Mask R-CNN и предложенного метода решения задачи.

В табл. 1 и 2 приведены результаты метрик IoU и Pixel Accuracy для архитектуры Mask R-CNN и предложенной архитектуры. Оба варианта решения оцениваются на основе пяти изображений из тестовой выборки. Метрика IoU вычисляется для каждого класса (пористость, кварц, рудные минералы, карбонатные минералы) отдельно, а также приводится среднее значение по всем классам (Mean IoU).

Таблица 1. Результаты метрик для модели Mask R-CNN

Образец	IoU, %					Pixel Accuracy, %
	Пористость	Кварц	Рудные минералы	Карбонатные минералы	Среднее значение IoU	
№ 1	7	78	0	69	39	77
№ 2	2	85	36	75	50	80
№ 3	5	83	26	72	47	78
№ 4	36	85	–	69	64	80
№ 5	51	88	–	75	54	85




Рис. 10. Сравнение результатов сегментации.

Таблица 2. Результаты метрик для предложенной архитектуры

Образец	IoU, %					Pixel Accuracy, %
	Пористость	Кварц	Рудные минералы	Карбонатные минералы	Среднее значение IoU	
№ 1	24	78	26	78	52	83
№ 2	13	87	45	84	57	87
№ 3	14	87	43	81	56	85
№ 4	74	89	–	79	81	86
№ 5	59	89	–	78	75	86

Сравнивая результаты обеих архитектур (табл. 3 и рис. 10), важно подчеркнуть, что оба решения достаточно хорошо распознают и классифицируют зёрна шлифов. Однако по средней метрике IoU и Pixel Accuracy предложенная архитектура показывает более высокие значения, чем Mask R-CNN. Это свидетельствует о том, что предложенная архитектура способна лучше сегментировать объекты на изображениях карбонатных песчаников.

Таблица 3. Сравнение результатов метрик

Образец	IoU, %					Pixel Accuracy, %
	Пористость	Кварц	Рудные минералы	Карбонатные минералы	Среднее значение IoU	
Mask R-CNN	20	84	21	72	50	80
Предложенная архитектура	37	86	38	80	64	86

8. Заключение

В результате проведённого исследования разработан метод автоматизированного анализа участков шлифов кварцевого песчаника с карбонатным цементом на основе глубокого обучения. Основной задачей была сегментация изображений шлифов для более точного выделения минеральных зёрен.

Для решения задачи сегментации был предложен комбинированный подход, объединяющий две современные модели: Mask R-CNN для экземплярной сегментации и SemanticFPN для семантической сегментации. Применение данных моделей в ансамбле позволило добиться высокой точности и качества сегментации, что подтверждено количественным сравнением результатов с помощью метрик Pixel Accuracy и IoU.

Результаты данного исследования имеют практическое применение и дополняют существующие подходы к автоматизированному анализу геологических данных.

Благодарности. Авторы выражают благодарность рецензентам за ценные замечания и предложения, которые способствовали улучшению работы.

Финансирование. Работа выполнена за счет средств Программы стратегического академического лидерства Казанского (Приволжского) федерального университета (Приоритет-2030).

Список литературы

- Гмид Л. П. Литологические аспекты изучения карбонатных пород-коллекторов // Нефтегазовая геология. Теория и практика. — 2006. — Т. 1. — С. 9.
- Данилова Т. Е. Терригенные породы девона и нижнего карбона. — Казань : Плутон, 2008. — 436 с.
- Морозов В. П. Учебно-методическое пособие к лабораторным занятиям по курсу «Литология». — Казань : Казанский университет, 2012. — 40 с.
- Муслимов Р. Х., Абдулмазитов Р. Г., Хисамов Р. Б. и др. Нефтегазоносность Республики Татарстан. Геология и разработка нефтяных месторождений. Том 1. — Казань : ФЭН АН РТ, 2007. — 316 с.
- Рыкус М. В. Карбонатная цементация в песчаных породах-коллекторах: обзор представлений // Нефтегазовое дело. — 2020. — Т. 18, № 5. — С. 15–26. — <https://doi.org/10.17122/ngdelo-2020-5-15-26>
- Caesar H., Uijlings J. and Ferrari V. COCO-Stuff: Thing and Stuff Classes in Context // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. — Salt Lake City, UT, USA : IEEE, 2018. — P. 1209–1218. — <https://doi.org/10.1109/cvpr.2018.00132>
- Dabek P., Chudy K., Nowak I., et al. Grain segmentation in sandstone thin-section based on computer analysis of microscopic images // IOP Conference Series: Earth and Environmental Science. — 2023. — Vol. 1189, no. 1. — P. 012026. — <https://doi.org/10.1088/1755-1315/1189/1/012026>
- Dell'Aversana P. An Integrated Deep Learning Framework for Classification of Mineral Thin Sections and Other Geo-Data, a Tutorial // Minerals. — 2023. — Vol. 13, no. 5. — P. 584. — <https://doi.org/10.3390/min13050584>
- Gadhiya Ravindra and Kalani Nilesh. Deep learning architectures for semantic segmentation of 2D image: A review // 1st International Conference on Advances in Signal Processing, VLSI, Communications and Embedded Systems: ICSVCE-2021. Vol. 2407. — AIP Publishing, 2021. — P. 020032. — <https://doi.org/10.1063/5.0074633>
- González-Vargas T. and Gutiérrez-Castorena M. D. C. Brightness Values-Based Discriminant Functions for Classification of Degrees of Organic Matter Decomposition in Soil Thin Sections // Spanish Journal of Soil Science. — 2022. — Vol. 12. — <https://doi.org/10.3389/sjss.2022.10348>
- He K., Gkioxari G., Dollár P., et al. Mask R-CNN // IEEE International Conference on Computer Vision (ICCV). — arXiv, 2017. — P. 2980–2988. — <https://doi.org/10.48550/ARXIV.1703.06870>
- Kerr P. F. Optical Mineralogy. — McGraw-Hill, 1977. — 492 p.
- Kirillov A., Girshick R., He K., et al. Panoptic Feature Pyramid Networks // IEEE Computer Vision and Pattern Recognition Conference (CVPR). — Long Beach, CA, USA : arXiv, 2019. — P. 6392–6401. — <https://doi.org/10.48550/ARXIV.1901.02446>
- Kirillov A., Wu Yu., He K., et al. PointRend: Image Segmentation as Rendering // IEEE Computer Vision and Pattern Recognition Conference (CVPR). — arXiv, 2020. — P. 9799–9808. — <https://doi.org/10.48550/ARXIV.1912.08193>

- Leichter A., Almeev R. R., Wittich D., et al. Automated Segmentation of Olivine Phenocrysts in a Volcanic Rock Thin Section Using a Fully Convolutional Neural Network // *Frontiers in Earth Science*. — 2022. — Vol. 10. — <https://doi.org/10.3389/feart.2022.740638>
- Lin T. Y., Maire M., Belongie S., et al. Microsoft COCO: Common Objects in Context // *Computer Vision – ECCV 2014*. — Cham : Springer International Publishing, 2014. — P. 740–755. — https://doi.org/10.1007/978-3-319-10602-1_48
- Padilla R., Netto S. L. and Silva E. A. B. da. A Survey on Performance Metrics for Object-Detection Algorithms // 2020 International Conference on Systems, Signals and Image Processing (IWSSIP). — Niteroi, Brazil : IEEE, 2020. — P. 237–242. — <https://doi.org/10.1109/iwssip48289.2020.9145130>
- Ren S., He K., Girshick R., et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. — 2017. — Vol. 39, no. 6. — P. 1137–1149. — <https://doi.org/10.1109/tpami.2016.2577031>
- Su C., Xu S. J., Zhu K. Y., et al. Rock classification in petrographic thin section images based on concatenated convolutional neural networks // *Earth Science Informatics*. — 2020. — Vol. 13, no. 4. — P. 1477–1484. — <https://doi.org/10.1007/s12145-020-00505-1>
- Wang H., Cao W., Zhou Y., et al. Multitarget Intelligent Recognition of Petrographic Thin Section Images Based on Faster RCNN // *Minerals*. — 2023. — Vol. 13, no. 7. — P. 872. — <https://doi.org/10.3390/min13070872>

APPLICATION OF NEURAL NETWORKS FOR IMAGE ANALYSIS OF THIN-SECTION AREAS OF QUARTZ SANDSTONE WITH CARBONATE CEMENT

R. F. Akhmetov^{1,*} , T. A. Murtazin¹ , V. P. Morozov¹ , D. N. Tumakov¹ , V. A. Sudakov¹ ,
D. K. Nurgaliev¹ , and Z. D. Kayumov² 

¹Kazan Federal University, Kazan, Russian Federation

²Geopy LLC, Kazan, Russian Federation

****Correspondence to:** Radik Akhmetov, axmetov.radi@mail.ru

Abstract: Petrographic analysis of thin sections of terrigenous rocks plays a key role in characterizing reservoir properties, enabling the assessment of textural and structural features as well as porosity—essential for reconstructing depositional environments and post-sedimentary alterations. Conventional manual analysis of thin sections is time-consuming and subjective, necessitating its automation. This study proposes an automated method for analyzing thin-section areas of quartz sandstone with carbonate cement based on deep learning, combining instance segmentation using the Mask R-CNN model with semantic segmentation employing SemanticFPN. This ensemble approach achieves high segmentation accuracy, as confirmed by Pixel Accuracy and Intersection over Union metrics, significantly accelerating petrographic data processing while enhancing objectivity and reproducibility. The method holds practical value for geological and petroleum exploration studies.

Keywords: petrographic thin section, mineral grain segmentation, sedimentary petrography, deep learning, artificial intelligence

RESEARCH ARTICLE

Received: October 14, 2025

Accepted: February 9, 2026

Published: August 28, 2026



© 2026. The Authors.

Citation: Akhmetov R. F., Murtazin T. A., Morozov V. P., Tumakov D. N., Sudakov V. A., Nurgaliev D. K., and Kayumov Z. D. (2026), Application of Neural Networks for Image Analysis of Thin-Section Areas of Quartz Sandstone with Carbonate Cement, *Russian Journal of Earth Sciences*, 26, ES3014, <https://doi.org/10.2205/2026ES001103>, EDN: BXIYSD

References

- Caeser H., Uijlings J. and Ferrari V. COCO-Stuff: Thing and Stuff Classes in Context // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. — Salt Lake City, UT, USA : IEEE, 2018. — P. 1209–1218. — <https://doi.org/10.1109/cvpr.2018.00132>
- Dabek P., Chudy K., Nowak I., et al. Grain segmentation in sandstone thin-section based on computer analysis of microscopic images // IOP Conference Series: Earth and Environmental Science. — 2023. — Vol. 1189, no. 1. — P. 012026. — <https://doi.org/10.1088/1755-1315/1189/1/012026>
- Danilova T. E. Terrigenous rocks of the Devonian and Lower Carboniferous. — Kazan : Pluton, 2008. — 436 p. — (In Russian).
- Dell'Aversana P. An Integrated Deep Learning Framework for Classification of Mineral Thin Sections and Other Geo-Data, a Tutorial // Minerals. — 2023. — Vol. 13, no. 5. — P. 584. — <https://doi.org/10.3390/min13050584>
- Gadhiya Ravindra and Kalani Nilesh. Deep learning architectures for semantic segmentation of 2D image: A review // 1st International Conference on Advances in Signal Processing, VLSI, Communications and Embedded Systems: ICSVCE-2021. Vol. 2407. — AIP Publishing, 2021. — P. 020032. — <https://doi.org/10.1063/5.0074633>
- Gmid L. P. Lithological aspects of the carbonate reservoir rocks study // Petroleum Geology – Theoretical and Applied Studies. — 2006. — Vol. 1. — P. 9. — (In Russian).

- González-Vargas T. and Gutiérrez-Castorena M. D. C. Brightness Values-Based Discriminant Functions for Classification of Degrees of Organic Matter Decomposition in Soil Thin Sections // Spanish Journal of Soil Science. — 2022. — Vol. 12. — <https://doi.org/10.3389/sjss.2022.10348>
- He K., Gkioxari G., Dollár P., et al. Mask R-CNN // IEEE International Conference on Computer Vision (ICCV). — arXiv, 2017. — P. 2980–2988. — <https://doi.org/10.48550/ARXIV.1703.06870>
- Kerr P. F. Optical Mineralogy. — McGraw-Hill, 1977. — 492 p.
- Kirillov A., Girshick R., He K., et al. Panoptic Feature Pyramid Networks // IEEE Computer Vision and Pattern Recognition Conference (CVPR). — Long Beach, CA, USA : arXiv, 2019. — P. 6392–6401. — <https://doi.org/10.4850/ARXIV.1901.02446>
- Kirillov A., Wu Yu., He K., et al. PointRend: Image Segmentation as Rendering // IEEE Computer Vision and Pattern Recognition Conference (CVPR). — arXiv, 2020. — P. 9799–9808. — <https://doi.org/10.48550/ARXIV.1912.08193>
- Leichter A., Almeev R. R., Wittich D., et al. Automated Segmentation of Olivine Phenocrysts in a Volcanic Rock Thin Section Using a Fully Convolutional Neural Network // Frontiers in Earth Science. — 2022. — Vol. 10. — <https://doi.org/10.3389/feart.2022.740638>
- Lin T. Y., Maire M., Belongie S., et al. Microsoft COCO: Common Objects in Context // Computer Vision – ECCV 2014. — Cham : Springer International Publishing, 2014. — P. 740–755. — https://doi.org/10.1007/978-3-319-10602-1_48
- Morozov V. P. Educational and methodological manual for laboratory classes in the course "Lithology". — Kazan : Kazan university, 2012. — 40 p. — (In Russian).
- Muslimov R. Kh., Abdulmazitov R. G., Khisamov R. B., et al. Oil and gas potential of the Republic of Tatarstan. Geology and development of oil fields. Volume 1. — Kazan : FEN AN RT, 2007. — 316 p. — (In Russian).
- Padilla R., Netto S. L. and Silva E. A. B. da. A Survey on Performance Metrics for Object-Detection Algorithms // 2020 International Conference on Systems, Signals and Image Processing (IWSSIP). — Niteroi, Brazil : IEEE, 2020. — P. 237–242. — <https://doi.org/10.1109/iwssip48289.2020.9145130>
- Ren S., He K., Girshick R., et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks // IEEE Transactions on Pattern Analysis and Machine Intelligence. — 2017. — Vol. 39, no. 6. — P. 1137–1149. — <https://doi.org/10.1109/tpami.2016.2577031>
- Rykus M. V. Carbonate cementation in sandstone reservoirs: an overview of views // Neftegazovoe delo. — 2020. — Vol. 18, no. 5. — P. 15–26. — <https://doi.org/10.17122/ngdelo-2020-5-15-26> — (In Russian).
- Su C., Xu S. J., Zhu K. Y., et al. Rock classification in petrographic thin section images based on concatenated convolutional neural networks // Earth Science Informatics. — 2020. — Vol. 13, no. 4. — P. 1477–1484. — <https://doi.org/10.1007/s12145-020-00505-1>
- Wang H., Cao W., Zhou Y., et al. Multitarget Intelligent Recognition of Petrographic Thin Section Images Based on Faster RCNN // Minerals. — 2023. — Vol. 13, no. 7. — P. 872. — <https://doi.org/10.3390/min13070872>