

УДК 004.8, 553.08

МРНТИ 28.23.15, 38.15.03

DOI: <https://doi.org/10.54859/kjogi108720>

Получена: 05.02.2024.

Одобрена: 12.06.2024.

Опубликована: 30.06.2024.

## Оригинальное исследование

# Кластеризация литотипов на основе визуальных признаков кернов с помощью свёрточных нейронных сетей и K-Means

Ф.С. Эбдіманап<sup>1,2</sup>, К.А. Бостанбеков<sup>1</sup>, А.Н. Алимова<sup>1</sup>, Н.Б. Салиев<sup>2</sup>,  
Д.Б. Нурсеитов<sup>1,2</sup>

<sup>1</sup>КМГ Инжиниринг, г. Астана, Казахстан

<sup>2</sup>Satbayev University, г. Алматы, Казахстан

## АННОТАЦИЯ

**Обоснование.** Литология изучает геологические породы и их характеристики, имеет важное значение в геологии и в нефтегазовой промышленности. Основными задачами литологии являются классификация горных пород, определение их происхождения, а также изучение условий их образования и изменения со временем. Литологические исследования керна проводятся различными методами – как традиционными (например, визуальное исследование образцов горных пород или микроскопический анализ шлифов), так и с использованием современных технологий. Традиционные методы изучения требуют высокой квалификации и опыта, и могут быть трудоёмкими, в особенности при визуальном анализе (описание кернового материала). Применение методов машинного обучения и автоматизированных технологий позволяет улучшить эффективность и точность анализа, сократить временные затраты и обеспечить быстрый доступ к информации.

**Цель.** Целью работы является разработка модели кластеризации литотипов на изображениях керна, используя методы машинного обучения.

**Материалы и методы.** В статье рассматривается алгоритм кластеризации литотипов методом K-Means в сочетании со свёрточными нейронными сетями VGG16, VGG19 и ResNet50 для выявления ключевых признаков (сходства и различий, определяемых по фото).

**Результаты.** Был разработан алгоритм кластеризации литотипов с помощью метода K-Means и свёрточных нейронных сетей. Определены преимущества и ограничения алгоритма при работе с изображениями кернов. Представлены результаты экспериментов, проведённых на реальном наборе данных.

**Заключение.** Результаты исследования предоставляют важные практические выводы, которые могут быть полезны в геологических исследованиях и в применении методов глубокого обучения для анализа керна. Дальнейшие исследования могут углубить анализ других моделей и методов машинного обучения, а также расширить область применения данного подхода в геологии.

**Ключевые слова:** литология, исследование керна, кластеризация литологии, машинное обучение, свёрточные нейронные сети.

## Как цитировать:

Эбдіманап Ф.С., Бостанбеков К.А., Алимова А.Н., Салиев Н.Б., Нурсеитов Д.Б. Кластеризация литотипов на основе визуальных признаков кернов с помощью свёрточных нейронных сетей и K-Means // Вестник нефтегазовой отрасли Казахстана. 2024. Том 6, №2. С. 25–38.  
DOI: <https://doi.org/10.54859/kjogi108720>.

UDC 004.8, 553.08

CSCSTI 28.23.15, 38.15.03

DOI: <https://doi.org/10.54859/kjogi108720>

Received: 05.02.2024.

Accepted: 12.06.2024.

Published: 30.06.2024.

## Original article

# Clustering of lithotypes based on visual features of cores using convolutional neural networks and K-Means

Galymzhan S. Abdimanap<sup>1,2</sup>, Kairat A. Bostanbekov<sup>1</sup>, Anel N. Alimova<sup>1</sup>,  
Nurlan B. Saliev<sup>2</sup>, Daniyar B. Nurseitov<sup>1,2</sup>

<sup>1</sup>KMG Engineering, Astana, Kazakhstan

<sup>2</sup>Satbayev University, Almaty, Kazakhstan

## ABSTRACT

**Background:** Lithology is a vital field of study in both geology and the oil and gas sector that focuses on the properties of geological rocks. The primary objectives of lithology to classify rocks, determine their origin, and investigate the conditions of their formation and changes over time. Lithological core examination employ various methods, encompassing both conventional techniques (e.g., visual inspection of the rock samples or microscopic analysis of slides) and modern technologies. Conventional methods of examination require high qualifications and experience, and can be labour-intensive, especially in visual analysis (description of core material). The application of machine learning methods and automated technologies can enhance the efficiency and accuracy of analysis, save time, and provide quick access to information.

**Aim:** To develop lithotypes clustering model on core images using machine learning methods.

**Materials and methods:** The paper discusses an algorithm for clustering lithotypes using K-Means method combined with VGG16, VGG19 and ResNet50 convolutional neural networks to identify key features (similarities and distinctions as determined from photos).

**Results:** The algorithm for clustering lithotypes using K-Means method and convolutional neural networks is developed. The advantages and limitations of the algorithm when working with core images are determined. Results from experiments conducted using an actual dataset are presented.

**Conclusion:** The findings of the study offer important practical insights that can be applied to deep learning methods for core analysis as well as geological research. The application of this approach in geology can be broadened and the analysis of alternative machine learning models and techniques can be strengthened with more investigation.

**Keywords:** lithology; core analysis; clustering lithology; machine learning; convolutional neural networks.

## To cite this article:

Abdimanap GS, Bostanbekov KA, Alimova AN, Saliev NB, Nurseitov DB. Clustering of lithotypes based on visual features of cores using convolutional neural networks and K-Means. *Kazakhstan journal for oil & gas industry*. 2024;6(2):25–38. DOI: <https://doi.org/10.54859/kjogi108720>.

ӨЖ 004.8, 553.08

ҒТАХР 28.23.15, 38.15.03

DOI: <https://doi.org/10.54859/kjogi108720>

Қабылданды: 05.02.2024.

Мақұлданды: 12.06.2024.

Жарияланды: 30.06.2024.

## Түпнұсқа зерттеу

# Түйіндемелі нейрондық желілер мен K-Means алгоритмін пайдалана отырып, керннің визуалды белгілеріне негізделген литотиптерді кластерлеу

Ғ.С. Әбдіманап<sup>1,2</sup>, Қ.А. Бостанбеков<sup>1</sup>, А.Н. Әлімова<sup>1</sup>, Н.Б. Салиев<sup>2</sup>,  
Д.Б. Нұрсейітов<sup>1,2</sup>

<sup>1</sup>ҚМГ Инжиниринг, Астана қаласы, Қазақстан

<sup>2</sup>Satbayev University, Алматы қаласы, Қазақстан

## АННОТАЦИЯ

**Негіздеу.** Литология геологиялық жыныстар мен олардың сипаттамаларын зерттейді, геология мен мұнай-газ өнеркәсібінде маңызды мәнге ие. Литологияның негізгі міндеттері тау жыныстарын жіктеу, олардың шығу тегін анықтау, сондай-ақ олардың пайда болу және уақыт өткен сайын өзгеру жағдайларын зерделеу болып табылады. Литологиялық зерттеулер әртүрлі әдістермен, соның ішінде дәстүрлі (мысалы, тау жыныстарының үлгілерін визуалды зерттеу немесе үлгілерді микроскопиялық талдау) және заманауи технологияларды қолдана отырып жүргізіледі. Дәстүрлі әдістер жоғары біліктілік пен тәжірибені талап етеді және оған көп уақыт жұмсау қажет, әсіресе визуалды талдау кезінде (керннің сипаттамасын жасау). Машиналық оқыту әдістері мен автоматтандырылған технологияларды қолдану талдаудың тиімділігі мен дәлдігін жақсартуға, уақыт шығындарын азайтуға және ақпаратқа жылдам қол жеткізуге мүмкіндік береді.

**Мақсаты.** Жұмыстың мақсаты машинамен оқыту әдістерін пайдалана отырып, керн бейнелеріндегі литотиптерді кластерлеу моделін әзірлеу болып табылады.

**Материалдар мен әдістер.** Мақалада литотиптерді K-Means әдісімен кластерлеу алгоритмі негізгі белгілерді (фотосурет бойынша анықталатын ұқсастықтар мен айырмашылықтар) анықтау үшін VGG16, VGG19 және ResNet50 түйіндемелі нейрондық желілерімен үйлесімде қарастырылады.

**Нәтижелері.** K-Means әдісі мен түйіндемелі нейрондық желілердің көмегімен литотиптерді кластерлеу алгоритмі әзірленді. Керн суреттерімен жұмыс істеу кезінде алгоритмнің артықшылықтары мен шектеулері анықталған. Нақты деректер жиынында жүргізілген эксперименттердің нәтижелері ұсынылды.

**Қорытынды.** Зерттеу нәтижелері геологиялық зерттеулерде және кернді талдау үшін терең оқыту әдістерін қолдануда пайдалы болуы мүмкін маңызды практикалық қорытындыларды ұсынады. Одан әрі зерттеулер машинамен оқытудың басқа модельдері мен әдістерін талдауды тереңдетуі, сондай-ақ геологияда осы тәсілді қолдану аясын кеңейтуі мүмкін.

**Негізгі сөздер:** литология, кернді зерттеу, литологияны кластерлеу, машиналық оқыту, түйіндемелі нейрондық желілер.

## Дәйексөз келтіру үшін:

Әбдіманап Ғ.С., Бостанбеков Қ.А., Әлімова А.Н., Салиев Н.Б., Нұрсейітов Д.Б. Түйіндемелі нейрондық желілер мен K-Means алгоритмін пайдалана отырып, керннің визуалды белгілеріне негізделген литотиптерді кластерлеу // Қазақстанның мұнай-газ саласының хабаршысы. 2024. 6 том, №2. 25–38 б.  
DOI: <https://doi.org/10.54859/kjogi108720>.

## Введение

Литология – область геологии, изучающая геологические породы и их характеристики, которая имеет важное значение в геологии, геофизике, нефтегазовой промышленности. Основные задачи литологии включают в себя классификацию горных пород, определение их происхождения, изучение условий их образования и изменения со временем. Литологические исследования ядра проводятся при помощи различных методов, включая визуальное исследование образцов горных пород, микроскопический анализ шлифов, химический анализ, методы каротажа ядра [1] с использованием современных технологий, таких как гиперспектральная визуализация и методы машинного обучения.

Традиционный анализ литологии требует высокой квалификации геологов и обширного опыта в визуальном определении пород. Такие методы, несмотря на свою эффективность, могут быть трудоёмкими и затратными по времени, особенно при обработке большого объёма образцов. Применение методов машинного обучения и автоматизированных технологий в области литологического анализа позволяет улучшить эффективность и точность оценок, сокращая временные затраты и обеспечивая более быстрый доступ к информации о горных породах. Перспективным направлением является определение литологии по фотографиям ядрового материала, т.е. образцов горных пород, выбуриваемых колонковым методом в процессе строительства скважин. Для определения литологии и проведения попытки сопоставления с лабораторным макрописанием ядра на основе изображений ядра в данной работе используется метод кластеризации. Кластеризация – это задача разделения данных на группы (кластеры) на основе их сходства в текстуре. Применение методов кластеризации к изображениям ядра может обеспечить эффективное разделение образцов по литологическим типам без явного указания эталонов или классов, что делает этот подход особенно ценным в условиях неполных или неоднозначных данных.

В последние годы активно проводятся исследования по применению методов машинного обучения для точной классификации литологии в образцах ядра, извлечённых из буровых скважин. В работе Corina A. и Novda S. [2] используются вероятностные нейронные сети для классификации литологии с данными каротажа для точного моделирования проницаемости ядра. He J. и др. [3] представляют многослойный перцептронный классификатор, использующий анализ фаций и статистическую классификацию, где приме-

няется обучающий набор данных, включающий данные каротажа и последовательности фаций. Zhang P. и др. [4] предлагают метод глубокого обучения с использованием свёрточной нейронной сети (далее – CNN, *англ.* Convolutional Neural Networks) для определения литологии на основе изображений, используя записи журнала регистрации по скважине. Сажа М. и др. [5] выявляют литологию на основе фотографий тонких срезов шламового материала, используя анализ изображений и обучение модели методу опорных векторов для определения категории каждого пикселя на изображении. Все эти исследования демонстрируют потенциал методов машинного обучения в области буровых работ и классификации литологии, а также предоставляют практические методики для повышения точности и эффективности анализа геологических данных.

## Материалы и методы

В целях кластеризации литологии необходимо выявить определенные закономерности (признаки) в структуре горных пород на изображении ядра. Для выявления этих признаков используются CNN. Архитектура CNN, направленная на распознавание образов, входит в состав технологий глубокого обучения, применяемых в различных областях, связанных с компьютерным зрением, таких как классификация текста, анализ настроений, машинный перевод, классификация изображений [6], распознавание речи, обнаружение и распознавание таблиц [7], распознавание рукописного текста [8, 9] и др.

CNN принимают изображения в качестве входных данных и автоматически присваивают настраиваемые веса и смещения различным объектам и признакам, что позволяет нейросети автоматически выделять и распознавать эти объекты и признаки. Это достигается с помощью последовательности слоёв, начиная со свёрточных слоёв, которые используют определённое количество ядер и нейронных весов для извлечения объектов и признаков. Затем функции активации изменяют масштаб объектов в нелинейной форме. Для уменьшения размерности объектов и выборки используются методы среднего и максимального объединения. Извлечённые объекты передаются в полностью связанные слои, где выполняются окончательная классификация и генерация прогнозов [10].

Основное различие между CNN и другими методами машинного обучения заключается в том, что CNN способны выполнять задачи без необходимости создания пользовательских функций вручную. Процесс обучения включает в себя автоматическое определение наилуч-

ших признаков для представления имеющихся данных. Во время обучения параметры нейросети инициализируются, и данные передаются через слои. Затем выходные данные нейросети сравниваются с исходными данными, используя функции потерь, и ошибка обратно распределяется для обновления фильтров и весов всех слоёв [11]. Этот процесс повторяется до достижения конвергенции нейросети. После обучения нейросеть генерирует прогнозы, обрабатывая данные в режиме прямой передачи и считывая выходные данные с конечного уровня.

После успешного извлечения признаков с изображений керны с помощью имеющихся моделей следующим этапом является применение кластеризации на основе алгоритма K-средних (K-Means). Алгоритм кластеризации K-Means был представлен в работе Steinhaus H. [12], широко используется в области машинного обучения и отличается эффективностью. Алгоритм K-Means – итеративный процесс, цель которого состоит в минимизации суммарного квадратичного отклонения точек каждого кластера от их центров, т.е. среднего значения точек в кластере. Каждая точка представляет собой вектор признаков изображений керны, полученных на предыдущем этапе выявления признаков.

Один из важных аспектов применения K-Means заключается в выборе оптимального числа кластеров K. Для определения этого параметра используется метод оценки силуэта [13], основанный на идее измерения степени сходства между объектами внутри кластера и степени различия между кластерами: чем выше среднее значение силуэта для всех объектов данных, тем лучше кластеризация. Значение показателя силуэта варьируется от -1 до 1: чем ближе значение силуэта к 1, тем лучше кластеризация, поскольку это означает, что объекты находятся ближе к своим собственным кластерам, чем к другим кластерам. Значение ближе к -1 указывает на неправильное присвоение объектов кластерам.

После завершения процесса кластеризации оценивается качество полученных кластеров с помощью таких метрик, как инерция, силуэтный коэффициент, индекс Дэвиса-Боулдина, Индекс Калински-Харабаса, который позволяет оценить степень разделения кластеров и их плотность. Эти результаты помогают определить, насколько эффективно алгоритм K-Means справился с задачей кластеризации литологических типов на основе изображений кернов. Результатом кластеризации является группировка изображений кернов в кластеры схожих по признакам объектов, что облегчает дальнейший анализ и интерпретацию данных.

## Набор данных

Исходные изображения представляют собой 4–6 м кернового материала, сложенных в один лоток по одному метру. Для дальнейшей работы образцы керны необходимо было разделить на отдельные метровые изображения кернов. Для автоматизации разделения на отдельные изображения была обучена нейронная модель Faster R-CNN. Для данной модели был создан первый набор данных, включающий 100 размеченных изображений керны с использованием инструмента VGG Image Annotator [14]. Для оптимизации процесса сбора датасета инструментов был модифицирован в виде веб-приложения, использующего фреймворк Flask, что позволяет нескольким пользователям одновременно взаимодействовать с инструментом (рис. 1). После обучения модели изображения керны были обрезаны на метровые и сохранены в отдельные файлы, что составило конечный датасет из изображений метровых кернов.

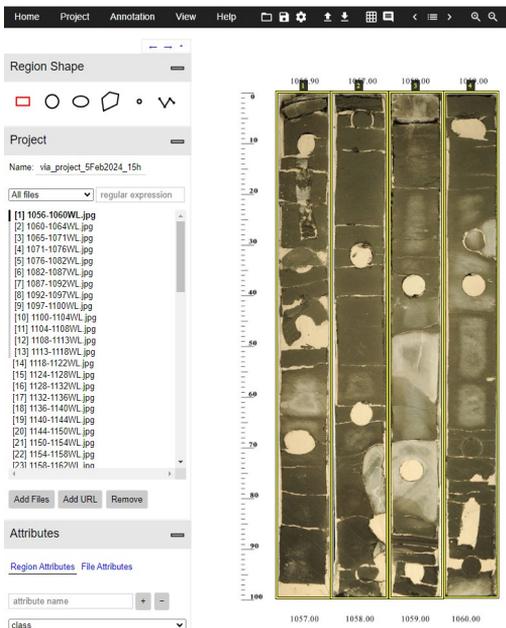
Далее каждые метровые фрагменты керны были разделены на фрагменты размером 32 x 32 пикселя, используя метод скользящего окна. Окно перемещалось с шагом 10 пикселей как в горизонтальном, так и в вертикальном направлениях, охватывая все участки изображения (рис. 2).

## Извлечение признаков с помощью CNN

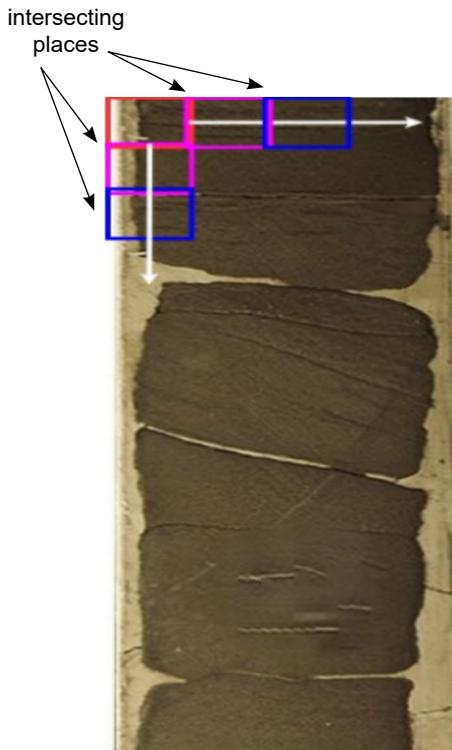
Качество и эффективность кластеризации напрямую зависит от точности и эффективности извлечения признаков из изображений керны: чем более информативные и репрезентативные признаки удаётся выделить из данных изображений, тем более точные и интерпретируемые кластеры могут быть сформированы, что способствует более качественному анализу и интерпретации литотипов. Для извлечения признаков использовались сверточные нейронные сети VGG16, VGG19 и ResNet50

Группа VGG [15] разработала 6 глубоких сверточных нейронных сетей, из которых VGG16 и VGG19 показали лучшие результаты. В свою очередь, они считают глубину наиболее важным параметром для оценки эффективности нейросети в распознавании и точной классификации CNN. В архитектуре данных нейросетей использовались фильтры размером 3 × 3 пикселя, включая последовательные фильтры для создания более широкого поля размером 5 × 5 пикселя. Также применялись 3 фильтра по 3 × 3 пикселя для формирования поля размером 7 × 7 пикселей. После каждой операции максимального объединения количество фильтров в архитектуре может удваиваться.

Архитектура нейросети VGG16 [15] включает 4 основные операции:



**Рисунок 1. Модифицированный инструмент разметки метровых кернов**  
**Figure 1. Modified meter core marking tool**



**Рисунок 2. Процесс создания датасета**  
**Figure 2. Dataset creation process**

1. Свертка (ConvNet). Этот этап извлекает признаки из изображений и сохраняет пространственную связь между пикселями, анализируя объекты в меньших квадратах с использованием свёрточных слоев размером  $3 \times 3$  пикселя.

2. Линейный блок с исправлением нелинейности (функции активации ReLU). Функции активации, такие как ReLU, добавляют нелинейность после свёрточных слоев.

3. Объединение в пул, или субдискретизация. Следующий слой после ReLU используется для уменьшения количества объектов, выбирая самые значимые элементы из карт объектов.

4. Полностью подключенный слой. Последний слой собирает дескрипторы объектов, преобразуя их в вектор. VGG16 использует свёрточные слои с увеличением глубины и завершается тремя полносвязными слоями с 4096 узлами, завершаясь классификатором Softmax.

Отмечено, что нейросеть VGG16 состоит из 13 свёрточных слоев и трех полносвязных слоев. Аналогично архитектура VGG19 включает 16 свёрточных слоев и 3 полносвязных слоя. Обе нейросети используют набор небольших свёрточных фильтров размером  $3 \times 3$  пикселя с шагом 1, с последующими нелинейными слоями. Глубокие архитектуры позволяют более эффективно анализировать сложные объекты, что приводит к повышенной точности прогнозирования.

Модель ResNet50 (Residual Network с 50 слоями) представляет собой архитектуру глубоких нейронных сетей, применяемую в области обработки изображений и задач компьютерного зрения [16]. Она состоит из 50 слоев и оснащена ключевой особенностью – блоками с остаточными соединениями (residual connections). Эти соединения позволяют эффективно обучать глубокие нейросети, предотвращая проблемы, связанные с затуханием градиента. Остаточные соединения позволяют пропускать входные данные через блок нейронов, облегчая процесс обучения и обеспечивая эффективность даже при большой глубине сети. Модель может адаптироваться к разным задачам благодаря гибкости блоков различной глубины. Важной особенностью является использование свертки  $1 \times 1$ ,  $3 \times 3$  и  $1 \times 1$  для извлечения признаков на разных уровнях абстракции.

Для извлечения признаков использовались модели VGG16 (рис. 3), VGG19 (рис. 4) и ResNet50 (рис. 5) с предобученными весами на датасете ImageNet, при этом были исключены полносвязные слои, необходимые для классификации. На входе моделей подавались изображения размером

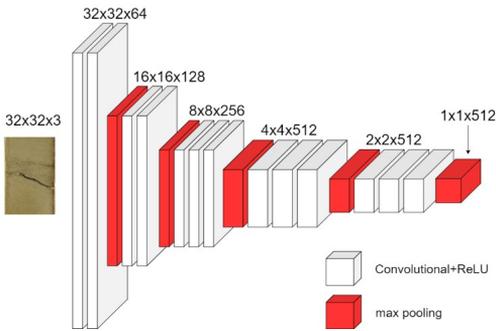


Рисунок 3. Архитектура VGG16  
Figure 3. VGG16 architecture

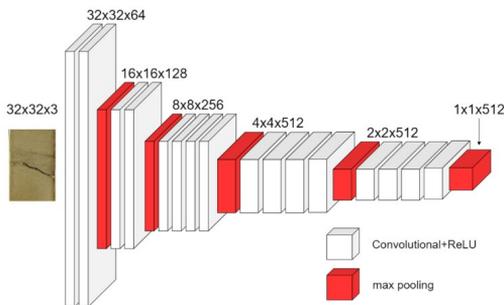


Рисунок 4. Архитектура VGG19  
Figure 4. VGG19 architecture

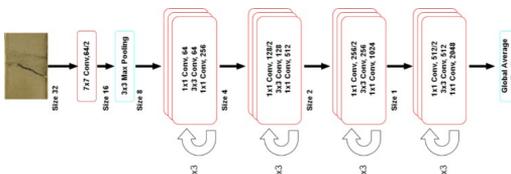


Рисунок 5. Архитектура модели ResNet50  
Figure 5. ResNet50 model architecture

32 × 32 пикселя, а на выходе были получены векторы размером 512, содержащие характерные признаки изображения.

### Результаты и их обсуждение

Ниже изложено краткое описание исходной фотографии ядерного материала (рис. 6). Данное описание было получено на основе заключения лабораторных исследований ядра.

#### 1-й метр слева:

- верхняя часть среза представлена песчаником мелкозернистым, цвет серый, с тонкими прослойками органических растительных остатков, слоистость горизонтально-наклонная, прерывистая;

- ближе к средней части район выбуривания 2-го и 3-го штупфов представлен массивным мелкозернистым песчаником, цвет серый;

- в нижней части разрез имеет резкую смену литологии с песчаника на алевролит, насыщенный органикой, цвет тёмно-серый, скрыто-слоистый, с тонкими трещинами по наслоению, о чём свидетельствует преобладание тёмных цветов.

#### 2-й метр:

- срез представлен в верхней части массивным мелкозернистым песчаником с глинистым цементом, цвет серый с буроватым оттенком;

- ниже в районе выбуривания 3-го штупфа видна резкая граница изменения литологии – переход к песчанику мелкозернистому, цвет светло-серый, с карбонатным цементом.

#### 3-й метр:

- представлен песчаником мелкозернистым с переслаиванием алевролитов, цвет красновато-бурый (гидроксиды железа), мелкие вкрапления пирита с массивной однородной текстурой;

- в средней части фото идёт чередование тонких прослоев песчаника мелкозернистого серого и алевролита тёмно-серого глинистого, с тонкими открытыми трещинами по наслоению (возможно, следы биотурбации в нижней части);

- в нижней части фото песчаник светло-серый, мелкозернистый, с редкими тонкими прослоями глинистого материала с тонкими открытыми трещинами.

#### 4-й метр:

- в верхней части срез представлен аргиллитами с тонким переслаиванием алевролитов и песчаником, местами однородным, коричневым, мелкозернистым, с включениями пирита (до района 1-го выбуренного штупфа);

- в средней части срез представлен серым мелкозернистым песчаником с серией глинистых слоев с включениями пирита и трещинами по наслоению, что свидетельствует о смене обстановки накопления материала;

- в нижней части среза нетрудно заметить изменение литологии – это переход от песчаников к темноцветным алевролитам с переслаиванием однородного песчаника коричневого, мелкозернистого, с включениями пирита.

В качестве входных данных для кластеризации было использовано исходное изображение ядра. Эксперименты проводились с применением алгоритма кластеризации K-Means и свёрточных моделей VGG16, VGG-19 и ResNet50, предназначенных для выявления признаков.

**Эксперимент 1.** В данном эксперименте использовалась модель VGG16 для выявления признаков. После отключения последних слоёв (полносвязных слоёв) создается нейросеть на основе исходной, где выходом этой

модели является выход 19-го слоя исходной модели VGG16. Этот выход используется для дальнейшей обработки и анализа признаков изображений.

**Эксперимент 2.** В этом эксперименте для выявления признаков используется архитектура VGG19. Модель VGG19 с отключенными последними слоями (полносвязные слои). Выходом этой модели является выход 22-го слоя исходной модели VGG19.

**Эксперимент 3.** В этом эксперименте для выявления признаков используется архитектура ResNet50. В данной архитектуре также были отключены последние слои (полносвязные слои). Выходом этой модели является выход 52-го слоя исходной модели ResNet50.

После использования моделей на полноценном датасете извлекаются признаки в виде набора векторов. Для разделения изображений на кластеры используются эти признаки в качестве входных данных

для алгоритма кластеризации K-Means. Для определения оптимального количества кластеров был выбран диапазон от 5 до 35 (с шагом 5) с применением метода оценки силуэта. Результаты оценки силуэта представлены на рис. 7–12.

При выборе конкретного количества кластеров (K) нужно следить за тем, чтобы все кластеры имели оценку силуэта выше средней оценки набора данных, обозначенной красной пунктирной линией на оси X. Кластер с  $K = 10$  удаляется, поскольку не соответствует этому условию. Также необходимо обращать внимание на размеры кластеров. Ширина кластера представляет собой количество точек данных. Например, при  $K = 5$  (бирюзовый) и  $K = 15$  (красный) кластер имеет почти вдвое большую, по сравнению с другими кластерами, ширину. Однако этот бирюзовый / красный кластер разбивается на подкластеры при  $K = 20, 25, 30$ , что приводит к кластерам, близким по размеру. Учитывая, что кластеры больше 20 не дают существенного улучшения, выбирают 20 как оптимальное количество кластеров.

На рис. 13 представлены результаты кластеризации с использованием модифицированной модели VGG16. На рис. 14 отображены результаты кластеризации с использованием модифицированной модели VGG19. На рис. 15 представлены результаты кластеризации с использованием модифицированной модели ResNet50. В табл. 1 представлены метрики оценки качества кластеризации на основе алгоритма K-Means и различных модифицированных нейросетей.

Для оценки качества кластеризации рассмотрим следующие метрики:

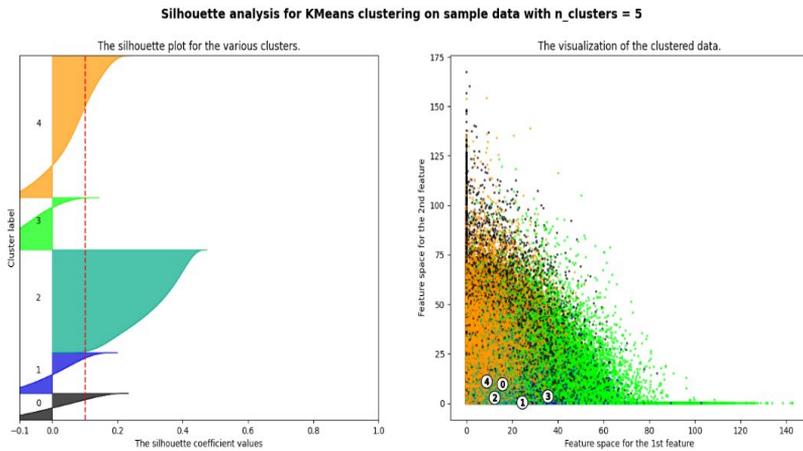
- инерция в кластеризации измеряет сумму квадратов расстояний между каждой точкой внутри кластера и его центроидом. Более низкое значение инерции свидетельствует о более компактных и однородных кластерах. Эта метрика полезна для определения оптимального числа кластеров и оценки качества кластеризации в методах, таких как k-средних [13];

- индекс силуэта представляет собой метрику качества кластеризации, измеряющую, насколько хорошо объекты внутри кластера схожи между собой и насколько отличны от объектов в других кластерах. Значения индекса силуэта находятся в диапазоне от -1 до 1: значение ближе к 1 указывает на хорошую кластеризацию, а ближе к -1 – на некорректное разделение объектов [13];

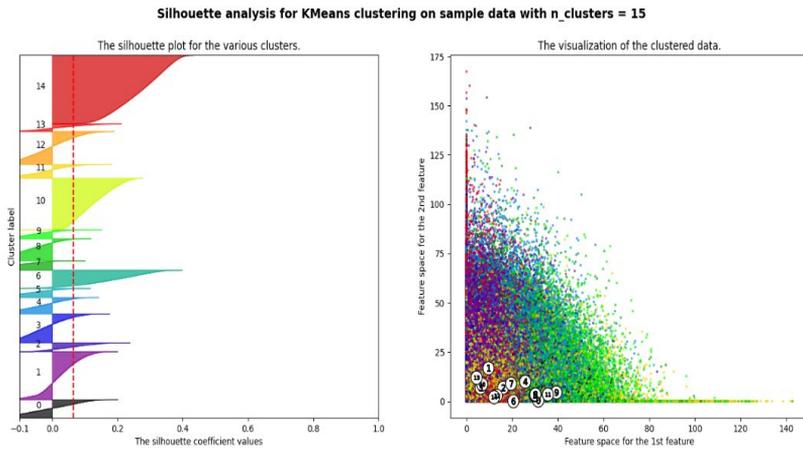
- индекс Дэвиса-Боулдина является метрикой внутренней качественной оценки кластеризации. Он оценивает, насколько кластеры компактны и однородны с учётом



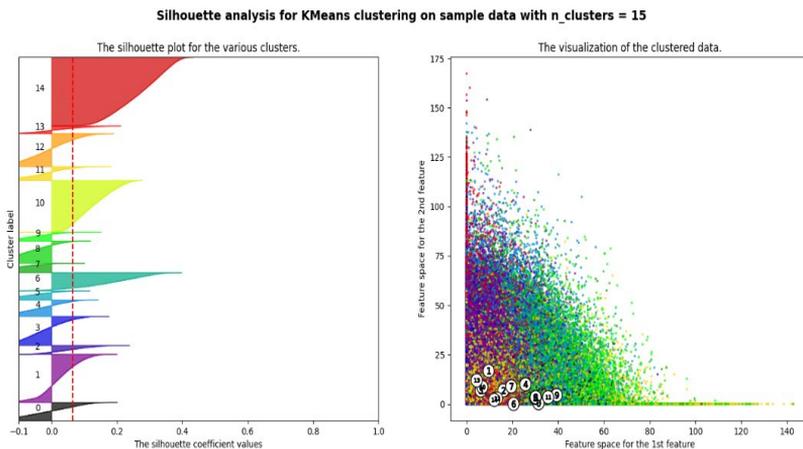
**Рисунок 6. Исходная фотография  
кernового материала**  
**Figure 6. Original photo of core material**



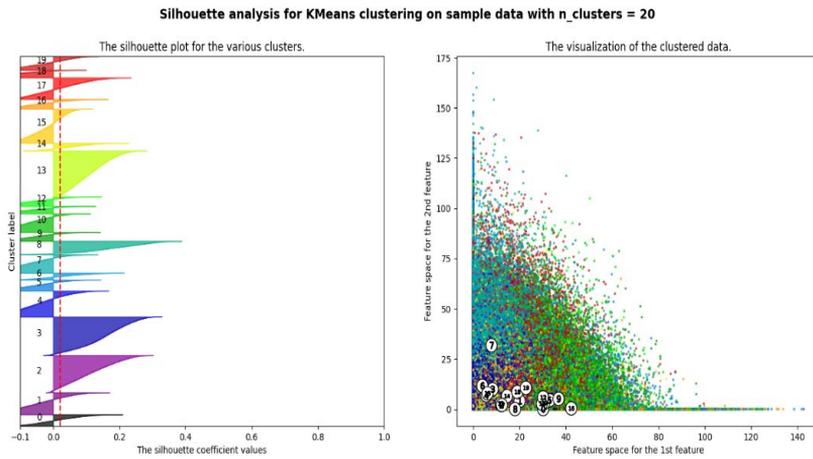
**Рисунок 7. Индекс силуэта для кластеризации с количеством 5 кластеров**  
**Figure 7. Silhouette clustering index with 5 clusters**



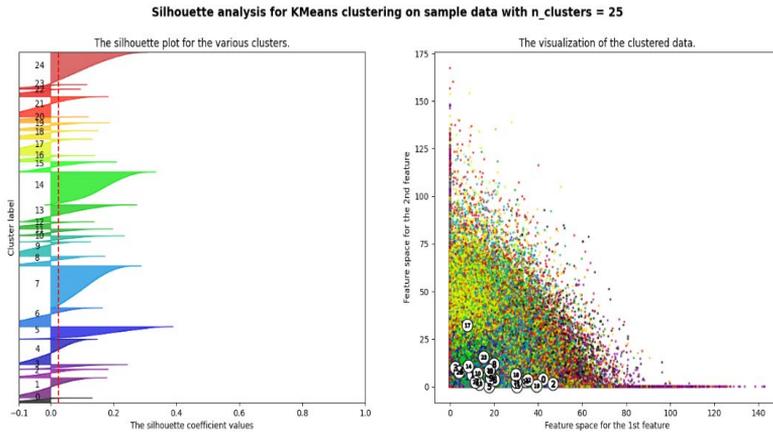
**Рисунок 8. Индекс силуэта для кластеризации с количеством 10 кластеров**  
**Figure 8. Silhouette clustering index with 10 clusters**



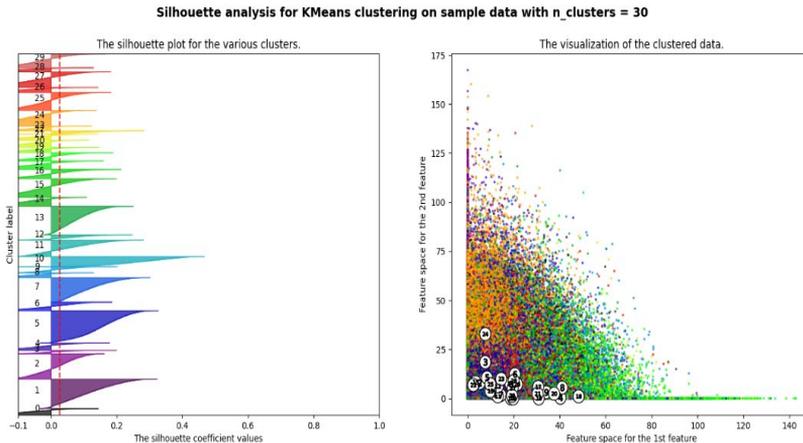
**Рисунок 9. Индекс силуэта для кластеризации с количеством 15 кластеров**  
**Figure 9. Silhouette clustering index clustering with 15 clusters**



**Рисунок 10. Индекс силуэта для кластеризации с количеством 20 кластеров**  
**Figure 10. Silhouette clustering index with 20 clusters**



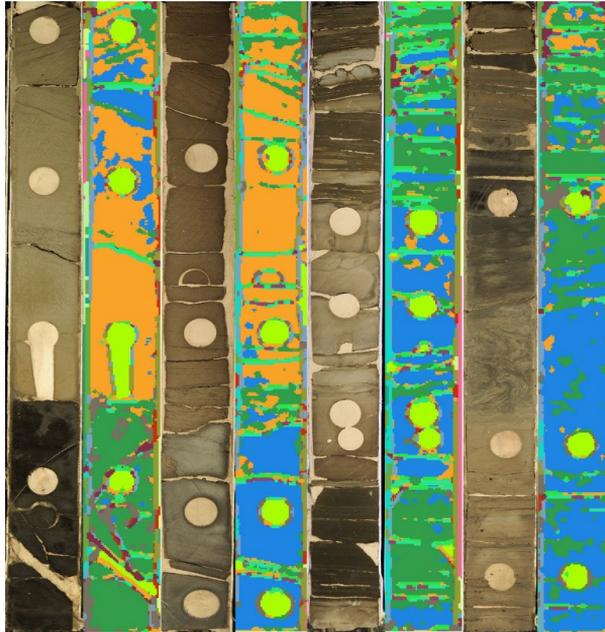
**Рисунок 11. Индекс силуэта для кластеризации с количеством 25 кластеров**  
**Figure 11. Silhouette clustering index with 25 clusters**



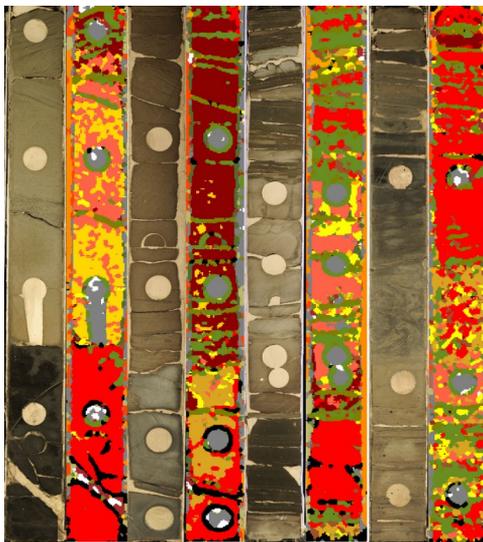
**Рисунок 12. Индекс силуэта для кластеризации с количеством 30 кластеров**  
**Figure 12. Silhouette clustering index with 30 clusters**

**Таблица 1. Метрики оценки качества кластеризации**  
**Table 1. Metrics for assessing clustering quality**

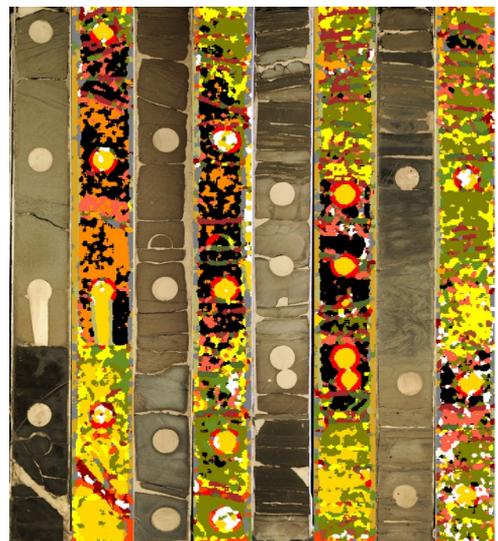
Метрики / Metrics	VGG16	VGG19	ResNet50
Инерция / Inertia	14 339 303 424,0	14 929 252 352,0	3 042 697 472,0
Индекс силуэта / Silhouette index	0,0393	0,0217	-0,0026
Индекс Дэвиса-Боулдина / Davis-Bouldin Index	2,8269	2,6669	3,1924
Индекс Калински-Харабаса / Kalinski-Harabas index	35 314,39	38 011,47	22 864,16



**Рисунок 13. Результаты кластеризации с использованием модели VGG16**  
**Figure 13. Clustering results using the VGG16 model**



**Рисунок 14. Результаты кластеризации с использованием модели VGG19**  
**Figure 14. Clustering results using the VGG19 model**



**Рисунок 15. Результаты кластеризации с использованием модели ResNet50**  
**Figure 15. Clustering results using the ResNet50 model**

минимизации внутрикластерных расстояний и максимизации межкластерных расстояний. Более низкое значение индекса Дэвиса-Боулдина указывает на более оптимальную и отделимую кластеризацию [13];

- в случае индекса Калински-Харабаса высокие значения указывают на более компактные и отделимые кластеры. Меньшие значения могут свидетельствовать о более разреженных кластерах или более широких диапазонах размеров кластеров [13].

Результаты кластеризации с использованием модифицированной модели ResNet50 показывают следующее: показатель инерции значительно ниже, что указывает на более компактные кластеры; показатель индекса силуэта отрицательный, что указывает на некорректное разделение объектов; значение индекса Дэвиса-Боулдина выше, чем у двух других моделей, что может свидетельствовать о менее компактных и менее однородных кластерах; значение индекса Калински-Харабаса меньше, чем у VGG моделей, что также может указывать на более разреженные кластеры. Таким образом, модель ResNet50 показывает менее оптимальные результаты и, следовательно, может быть менее подходящей для кластеризации изображений ядра.

Результаты кластеризации с использованием модифицированных моделей VGG16 и VGG19 очень схожи друг с другом и имеют небольшие колебания в значениях. Низкое значение инерции у модели VGG16 свидетельствует о более компактных и од-

нородных кластерах. Значения индекса силуэта у модели VGG16 ближе к 1, что указывает на хорошую кластеризацию. Показатель индекса Дэвиса-Боулдина у модели ниже VGG19, чем у VGG16, и указывает на более оптимальную и отделимую кластеризацию. Индекс Калински-Харабаса имеет высокое значение у модели VGG19, что может указывать на компактность и отделимость кластеров. В целом выбор между моделями будет зависеть от конкретных требований задачи.

### Выводы

Анализ метрик указывает на то, что в задаче кластеризации изображений ядер модели VGG16 и VGG19 демонстрируют схожие результаты. В модели VGG16 наилучшие показатели у метрик инерции и индекса силуэта, а у модели VGG19 лучшие показатели в метриках индекса Дэвиса-Боулдина и индекса Калински-Харабаса. Эти факторы свидетельствуют о более компактных, разделимых и различных кластерах.

Визуальный анализ также подтверждает, что модели группы VGG показывают лучшие результаты по сравнению с ResNet50.

Эти результаты предоставляют важные практические исследовательские выводы, которые могут быть полезны в геологических исследованиях и применении методов глубокого обучения для анализа ядра. Дальнейшие исследования могут углубить анализ других моделей и методов кластеризации, а также расширить область применения данного подхода в геологии.

### ДОПОЛНИТЕЛЬНО

**Источник финансирования.** Авторы заявляют об отсутствии внешнего финансирования при проведении исследования.

**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 подготовку статьи, прочли и одобрили финальную версию перед публикацией). Наибольший вклад распределён следующим образом: Эбдиманап Ф.С. – сбор и обработка данных, Бостанбеков К.А. – разработка алгоритма кластеризации, Алимова А.Н. – обработка результатов, сбор и написание статьи, Салиев Н.Б. – литологическое

описание ядра, Нурсейтов Д.Б. – концепция исследования и общая редакция статьи.

### ADDITIONAL INFORMATION

**Funding source.** This study was not supported by any external sources of funding.

**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. The greatest contribution is distributed as follows: Galymzhan S. Abdimanap – data collection and processing; Kairat A. Bostanbekov – development of clustering algorithm; Anel N. Alimova – processing of results, writing of the article; Nurlan B. Saliev – lithologic description of the core; Daniyar B. Nurseitov – research concept and article editing.

## СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. *Gandhi S.M., Sarkar B.C.* Essentials of mineral exploration and evaluation. Elsevier, 2016. 410 p.
2. *Corina A.N., Hovda S.* Automatic lithology prediction from well logging using kernel density estimation // *Journal of Petroleum Science and Engineering*. 2018. Vol. 170. P. 664–674. doi:10.1016/j.petrol.2018.06.012.
3. *He J., La Croix A.D., Wang J., et al.* Using neural networks and the Markov Chain approach for facies analysis and prediction from well logs in the Precipice Sandstone and Evergreen Formation, Surat Basin, Australia // *Marine and Petroleum Geology*. 2019. Vol. 101. P. 410–427. doi:10.1016/j.marpetgeo.2018.12.022.
4. *Zhang P., Sun J., Jiang Y., Gao J.S.* Deep learning method for lithology identification from borehole images // 79th EAGE conference and exhibition; 2017 Jun; Paris, France. Режим доступа: <https://www.earthdoc.org/content/papers/10.3997/2214-4609.201700945>. Дата обращения: 11.01.2024.
5. *Caja M.A., Pena A.C., Campos J.R., et al.* Image processing and machine learning applied to lithology identification, classification and quantification of thin section cutting samples // SPE Annual technical conference and exhibition; 2019 Sept 30 – Oct 2; Calgary, Canada. Режим доступа: <https://onepetro.org/SPEATCE/proceedings-abstract/19ATCE/2-19ATCE/D022S083R001/217751>. Дата обращения: 12.01.2024.
6. *Wang J., Yang Y., Mao J., et al.* CNN-RNN: A unified framework for multi-label image classification // 2016 IEEE conference on computer vision and pattern recognition (CVPR); 2016 Dec 12; Las Vegas, USA. Режим доступа: <https://ieeexplore.ieee.org/document/7780620>. Дата обращения: 15.01.2024.
7. *Abdallah A., Berendeyev A., Nuradin I., Nurseitov D.* TNCR: Table net detection and classification dataset // *Neurocomputing*. 2022. Vol. 473. P. 79–97. doi:10.1016/j.neucom.2021.11.101.
8. *Nurseitov D., Bostanbekov K., Kurmankhojayev D., et al.* Handwritten Kazakh and Russian (HKR) database for text recognition // *Multimedia tools and applications*. 2021. Vol. 80, N 21. P. 33075–33097. doi:10.1007/s11042-021-11399-6.
9. *Nurseitov D., Bostanbekov K., Kanatov M., et al.* Classification of handwritten names of cities and handwritten text recognition using various Deep learning models // *Advances in science, technology and engineering systems journal*. 2020. Vol. 5, N 5. P. 934–943. doi:10.25046/aj0505114.
10. *Goodfellow I., Bengio Y., Courville A.* Deep learning. Cambridge : MIT Press, 2016. 801 p.
11. *LeCun Y., Bengio Y., Hinton G.* Deep learning // *Nature*. 2015. Vol. 521. P. 436–444. doi:10.1038/nature14539.
12. *Steinhaus H.* Sur la division des corps materiels en parties // *Bulletin Lacademie Polonaise des Science*. 1957. Vol. 4. P. 801–804.
13. [scikit-learn.ru/clustering](https://scikit-learn.ru/clustering) [интернет]. Scikit-learn developers (BSD License) [дата обращения: 20.12.2023]. Доступ по ссылке: <https://scikit-learn.ru/clustering/>.
14. *Dutta A., Zisserman A.* The Via Annotation software for images, audio and video // 27th ACM international conference on multimedia; 2019 Oct 21–25; Nice, France. Режим доступа: <https://dl.acm.org/doi/10.1145/3343031.3350535>. Дата обращения: 18.01.2024.
15. *Simonyan K., Zisserman A.* Very deep convolutional networks for large-scale image recognition // *International Conference on Learning Representations*. 2015. doi:10.48550/arXiv.1409.1556.
16. *Krizhevsky A., Sutskever I., Hinton G.* ImageNet classification with deep convolutional neural networks // *Communications of the ACM*. 2017. Vol. 60, N 6. P. 84–90. doi:10.1145/3065386.

## REFERENCES

1. *Gandhi SM, Sarkar BC.* *Essentials of mineral exploration and evaluation*. Elsevier; 2016. 410 p.
2. *Corina AN, Hovda S.* Automatic lithology prediction from well logging using kernel density estimation. *Journal of Petroleum Science and Engineering*. 2018;170:664–674. doi:10.1016/j.petrol.2018.06.012.
3. *He J, La Croix AD, Wang J, et al.* Using neural networks and the Markov Chain approach for facies analysis and prediction from well logs in the Precipice Sandstone and Evergreen Formation, Surat Basin, Australia. *Marine and Petroleum Geology*. 2019;101:410–427. doi:10.1016/j.marpetgeo.2018.12.022.
4. *Zhang P, Sun J, Jiang Y, Gao JS.* Deep learning method for lithology identification from borehole images. 79th EAGE conference and exhibition; 2017 Jun; Paris, France. Available from: <https://www.earthdoc.org/content/papers/10.3997/2214-4609.201700945>.
5. *Caja MA, Pena AC, Campos JR, et al.* Image processing and machine learning applied to lithology identification, classification and quantification of thin section cutting samples. SPE Annual technical conference and exhibition; 2019 Sept 30 – Oct 2; Calgary, Alberta, Canada. Available from: <https://onepetro.org/SPEATCE/proceedings-abstract/19ATCE/2-19ATCE/D022S083R001/217751>.
6. *Wang J, Yang Y, Mao J, et al.* CNN-RNN: A unified framework for multi-label image classification. 2016 IEEE conference on computer vision and pattern recognition (CVPR); 2016 Dec 12; Las Vegas, USA. Available from: <https://ieeexplore.ieee.org/document/7780620>.

7. Abdallah A, Berendeyev A, Nuradin I, Nurseitov D. TNCR: Table net detection and classification dataset. *Neurocomputing*. 2022;473:79–97. doi:10.1016/j.neucom.2021.11.101.
8. Nurseitov D, Bostanbekov K, Kurmankhojayev D, et al. Handwritten Kazakh and Russian (HKR) database for text recognition. *Multimedia tools and applications*. 2021;80(21): 33075–33097. doi:10.1007/s11042-021-11399-6.
9. Nurseitov D., Bostanbekov K., Kanatov M., et al. Classification of handwritten names of cities and handwritten text recognition using various Deep learning models. *Advances in science, technology and engineering systems journal*. 2020;5(5):934–943. doi:10.25046/aj0505114.
10. Goodfellow I, Bengio Y, Courville A. *Deep learning*. Cambridge: MIT Press; 2016. 801 p.
11. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521:436–444. doi:10.1038/nature14539.
12. Steinhaus H. Sur la division des corps materiels en parties. *Bulletin Lacademie Polonaise des Science*. 1957;4:801-804.
13. scikit-learn.ru/clustering [Internet]. Scikit-learn developers (BSD License) [cited 20.12.2023]. Available from: <https://scikit-learn.ru/clustering/>.
14. Dutta A, Zisserman A. The Via Annotation software for images, audio and video. 27th ACM international conference on multimedia; 2019 Oct 21–25; Nice, France. Available from: <https://dl.acm.org/doi/10.1145/3343031.3350535>.
15. Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *International Conference on Learning Representations*. 2015. doi:10.48550/arXiv.1409.1556.
16. Krizhevsky A, Sutskever I, Hinton G. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*. 2017;60(6):84–90. doi:10.1145/3065386.

## ИНФОРМАЦИЯ ОБ АВТОРАХ

**Әбдіманап Ғалымжан Сейтахметғалиұлы**

ORCID [0000-0003-1676-4075](https://orcid.org/0000-0003-1676-4075)

e-mail: [g.abdimanap@kmge.kz](mailto:g.abdimanap@kmge.kz).

**Бостанбеков Кайрат Аратович**

PhD,

ORCID [0000-0003-2869-772X](https://orcid.org/0000-0003-2869-772X)

e-mail: [k.bostanbekov@kmge.kz](mailto:k.bostanbekov@kmge.kz).

**\*Алимова Анель Нурданбековна**

PhD,

ORCID [0000-0002-5155-2417](https://orcid.org/0000-0002-5155-2417)

e-mail: [a.alimova@kmge.kz](mailto:a.alimova@kmge.kz).

**Салиев Нурлан Бақитжанович**

ORCID [0009-0001-6537-6960](https://orcid.org/0009-0001-6537-6960)

e-mail: [saliyevnurlan@gmail.com](mailto:saliyevnurlan@gmail.com).

**Нурсейтов Данияр Борисович**

канд. физ.-мат. наук,

ассоциированный профессор

ORCID [0000-0003-1073-4254](https://orcid.org/0000-0003-1073-4254)

e-mail: [d.nurseitov@kmge.kz](mailto:d.nurseitov@kmge.kz).

## AUTHORS' INFO

**Galymzhan S. Abdimanap**

ORCID [0000-0003-1676-4075](https://orcid.org/0000-0003-1676-4075)

e-mail: [g.abdimanap@kmge.kz](mailto:g.abdimanap@kmge.kz).

**Kairat A. Bostanbekov**

PhD,

ORCID [0000-0003-2869-772X](https://orcid.org/0000-0003-2869-772X)

e-mail: [k.bostanbekov@kmge.kz](mailto:k.bostanbekov@kmge.kz).

**\*Anel N. Alimova**

PhD,

ORCID [0000-0002-5155-2417](https://orcid.org/0000-0002-5155-2417)

e-mail: [a.alimova@kmge.kz](mailto:a.alimova@kmge.kz).

**Nurlan B. Saliev**

ORCID [0009-0001-6537-6960](https://orcid.org/0009-0001-6537-6960)

e-mail: [saliyevnurlan@gmail.com](mailto:saliyevnurlan@gmail.com).

**Нурсейтов Данияр Борисович**

Cand. Sc. (Physics and Mathematics),

professor (associate)

ORCID [0000-0003-1073-4254](https://orcid.org/0000-0003-1073-4254)

e-mail: [d.nurseitov@kmge.kz](mailto:d.nurseitov@kmge.kz).

\*Автор, ответственный за переписку/Corresponding Author