

УДК 550.834  
DOI: 10.18799/24131830/2024/9/4792  
Шифр специальности ВАК: 1.2.1, 1.6.11

## Анализ применения методов машинного обучения в задачах классификации пород на образцах керна

А.И. Кочегуров, В.И. Денисов✉, Е.А. Задорожных

Национальный исследовательский Томский политехнический университет, Россия, г. Томск

✉10rnet.dv@gmail.com

**Аннотация. Актуальность.** Исследования керна в нефтегазовой отрасли позволяют получить некоторые фильтрационно-емкостные характеристики горных пород, а также дать представление о самом составе и строении недр. Данная информация крайне важна на первых этапах разработки месторождений, так как позволяет сформировать первичный вариант проекта разработки, который далее уточняется по ходу разбуривания месторождения. Однако выполнение анализа керна и его описание является крайне трудоемкой и подверженной влиянию человеческого фактора работой, требующей автоматизации. Таким образом, исследование изображений керна – востребованная задача в нефтегазовой отрасли, которая требует высокой точности и внимательности в ходе работы; особенно учитывая объем изображений, который приходится анализировать. **Целью** данной работы является обзор и анализ существующих алгоритмов классификации пород по изображениям керна на основе методов машинного обучения, а также использование полученной информации для формирования рекомендаций для развития данных алгоритмов. **Методы:** методы машинного обучения, в том числе нейронные сети. **Результаты.** Проведен анализ существующих подходов к исследованию образцов керна. Были отмечены основные преимущества и недостатки каждого из них, и на основании сделанных выводов разработан план и требования к проведению дальнейшего исследования образцов керна средствами машинного обучения. С применением сверточной нейронной сети на архитектуре U-Net была обучена модель для решения задачи сегментации образцов керна на дневных изображениях; приведены результаты работы модели.

**Ключевые слова:** исследование образцов керна, машинные методы обучения, сегментация и классификация, нейронные сети

**Благодарности:** Работа выполнена при поддержке гранта РНФ (№ 23-21-00259).

**Для цитирования:** Кочегуров А.И., Денисов В.И., Задорожных Е.А. Анализ применения методов машинного обучения в задачах классификации пород на образцах керна // Известия Томского политехнического университета. Инжиниринг георесурсов. – 2024. – Т. 335. – № 9. – С. 148–159. DOI: 10.18799/24131830/2024/9/4792

---

UDC 550.834  
DOI: 10.18799/24131830/2024/9/4792

## Analysis of applying machine learning methods in rock classification problems on core samples

A.I. Kochegurov, V.I. Denisov✉, E.A. Zadorozhnykh

National Research Tomsk Polytechnic University, Tomsk, Russian Federation

✉10rnet.dv@gmail.com

**Abstract. Relevance.** Core studies in the oil and gas industry allow us to obtain some filtration and capacity characteristics of rocks, as well as to give an idea of the composition and structure of the subsoil. This information is extremely important in the early stages of field development, as it allows us to formulate a primary version of the development project, which is then refined during the course of field drilling. However, core analysis and description are an extremely labor-intensive and human-influenced works that require automation. Thus, core image research is a popular task in the oil and gas industry that requires high accuracy and care during work; especially considering the volume of images that have to be analyzed. **Aim.** To

review and analyze existing algorithms for classifying rocks from core images based on machine learning methods; as well as to use the information obtained to formulate recommendations for the development of these algorithms. **Methods.** Machine learning methods, including neural networks. **Results.** The work analyzed existing approaches to the study of core samples. The main advantages and disadvantages of each of them were noted and, based on the findings, a plan and requirements for conducting further research on core samples using machine learning were developed. As a result, using a convolutional neural network on the U-Net architecture, the authors have trained a model to solve the problem of segmentation of core samples in daytime images and presented the results of the model operation.

**Keywords:** core sample research, machine learning methods, segmentation and classification, neural networks

**Acknowledgements:** The research was supported by RSF (project no. 23-21-00259).

**For citation:** Kochegurov A.I., Denisov V.I., Zadorozhnykh E.A. Analysis of applying machine learning methods in rock classification problems on core samples. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*, 2024, vol. 335, no. 9, pp. 148–159. DOI: 10.18799/24131830/2024/9/4792

## Введение

В настоящее время автоматизация работы специалистов при помощи специализированного программного обеспечения (ПО) не является чем-то новым. Сам процесс автоматизации зародился очень давно и продолжается до сих пор, меняя лишь свой облик.

Среди преимуществ автоматизации на основе информационных технологий можно отметить следующее: увеличение производительности и эффективности процесса; часто значительное сокращение времени выполнения задачи; лучший контроль за текущим процессом и связанными с ним данными, а также его прозрачность и видимость; немаловажным является стандартизация полученного результата и самого процесса; снижение ошибки, связанной с человеческим фактором.

Не исключением стала и область исследования образцов керн. Керн представляет собой некоторый объем горной породы, обычно в виде образца цилиндрической формы. Именно на основе анализа керн устанавливаются значения характеристик пласта и выводятся зависимости, позволяющие строить гидродинамические модели месторождений, без которых сейчас немислим сам процесс разработки недр [1].

Изображения образцов керн позволяют:

- запечатлеть исходный вид и положение керн, что делает возможным восстановление информации об образце в случае деформации/утраты по каким-либо причинам;
- получить представление о строении разреза скважины;
- сделать предположение о нефтенасыщенных интервалах, за счет чего можно сделать предварительное заключение о нефтенасыщенности;
- определить маркирующие слои и стратиграфические границы;
- спрогнозировать распространение коллекторов и флюидоупоров и их свойства;
- получить представление о некоторых параметрах пород: текстуре, литологической разности,

структуре, а также об их гелого-физических характеристиках;

- перечисленные выше данные позволяют сформировать базу, которая в последующем позволит подбирать месторождения-аналоги по параметрам керн.

Главная цель анализа керн – получение данных о недрах. Проведенные исследования породы дают возможность говорить о строении геологического разреза, геолого-физических характеристиках объекта и составе пород, геохимических показателях и насыщении пластов, а также о положении стратиграфических границ, реперных слоев и нахождении коллекторов.

Таким образом, керн является крайне важным источником информации, который оказывает сильное влияние на способ разработки месторождения. Изображения пород представляют собой один из основных источников информации для проведения литолого-фациального анализа на ранних этапах разработки. Кроме прочего, по фотографиям керн можно провести реконструкцию условий осадконакопления.

В общем случае можно сказать, что исследование керн является эффективным инструментом прогноза геологического разреза, решению задач которого посвящено достаточно большое число работ, в том числе на основе результатов фазочастотного прослеживания сейсмических волн [2–4].

## Применение нейронных сетей для классификации пород на образцах керн

В настоящее время применение современных технологий, таких как машинное обучение, для анализа образцов керн является распространенным методом исследования. Данная тенденция, как отмечалось выше, является следствием большого объема информации, которую требуется обработать, а также сложности идентификации пород при решении задачи классификации. В этом плане значительное место занимают методы машинного обучения, и прежде всего нейронные сети.

Вопросам использования нейронных сетей для классификации пород на образцах керна посвящен ряд работ, среди них важное место занимают исследования А. Пателя [5–7], наиболее интересные результаты которых опубликованы в [5, 6]. Так, в [5] описывается процесс автоматизации, анализа и классификации типов известняковых пород на основе импульсной нейронной сети. Ценность рассматриваемой работы заключается в том, что автор отходит от наиболее часто используемой в подобных работах сверточной нейронной сети и применяет импульсную нейронную сеть (pulsed neural network – PNN). Особенностью данного вида сетей является то, что они способны распознать целый класс (объект) по малому количеству пикселей в

динамическом кадре. Эти сети очень близки к мозгу и состоят из очень большого количества узлов

Автор обосновывает свой выбор тем, что вероятностный нейрон сети имеет сходство с моделью обратного распространения в том, как он направляется. Однако у PNN есть отличия в процедуре обучения. Архитектура PNN состоит из входного слоя, слоя паттернов (pattern layer), слоя суммирования и выходного слоя. Слой паттернов имеет сходство с сетью с радиальными функциями, однако слой суммирования имеет подобие конкурентной сети. Архитектура PNN, использованная автором, показана на рис. 1.

Методология классификации, предложенная в [5], изображена на рис. 2.

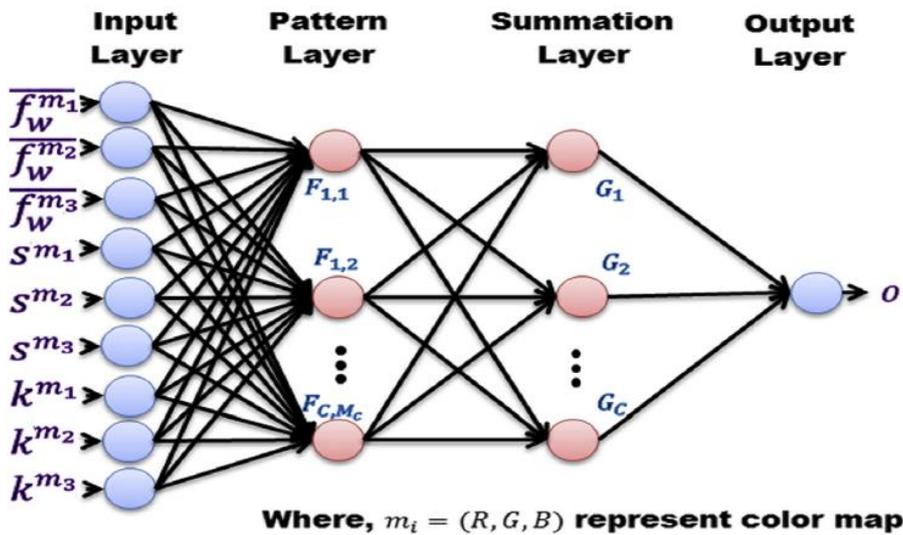


Рис. 1. Архитектура PNN  
 Fig. 1. PNN architecture

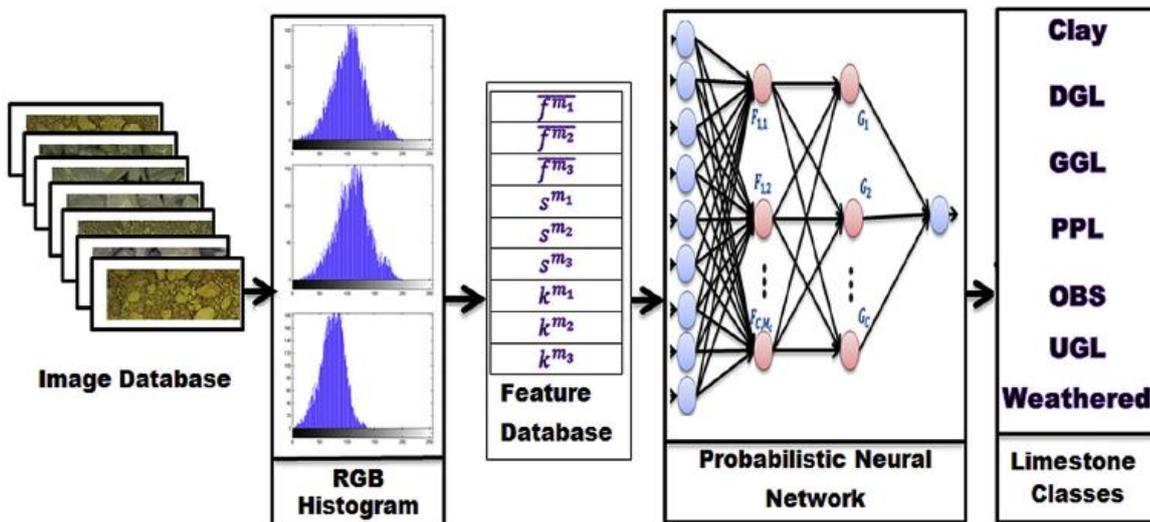


Рис. 2. Методология классификации  
 Fig. 2. Classification methodology

Среди прочего стоит отметить, что в работе использовались унифицированные входные данные, собранные одним исследователем в едином виде. Кроме того, отсутствует анализ работы на реальных геологических образцах со сложными структурными и текстурными особенностями.

В заключение автор говорит, что основным ограничением данного исследования является то, что использовались цельные куски горных пород, в которые были вкраплены более мелкие образцы горных пород. Таким образом, алгоритм будет работать корректно только тогда, когда тип породы всех мелких включений в образце одинаков. Данная проблема может быть нивелирована путем сегментации изображения – тогда алгоритм и классификацию можно будет применять к различным включениям на изображении.

В [6] описывается проектирование и разработка системы на основе искусственных нейронных сетей с целью автоматизированного определения характеристик угля. Особенностью рассматриваемой системы является то, что она использует сегментацию изображения для дальнейшей классификации объектов. Другими словами, на исходном изображении отбрасывается фон, а далее рассматриваются только сами образцы угля. Методология данной системы представлена на рис. 3.

Последующий анализ выделенных образцов угля выполняется при помощи анализа их цветности. Обученная сеть по цветности пород выделяет основные характеристики. Примеры анализа цветности пород по цифровым изображениям керна, представленные в литературных источниках, будут рассмотрены ниже.



Рис. 3. Методология системы  
 Fig. 3. System methodology

Еще одно важное и интересное исследование применения нейронных сетей для анализа пород рассмотрено в работе [8]. Здесь авторы приводят результаты исследования, целью которого было создание алгоритма, позволяющего определить тип породы образца керна. Одна из основных особенностей работы заключается в том, что авторами был избран подход, согласно которому производится сегментация изображения с заданным шагом. После этого для каждого полученного сегмента вычисляется вероятность нахождения в нём конкретного типа породы (рис. 4). Кроме того, если это возможно, то еще определялись дополнительные параметры (нефтенасыщенность, пористость, проницаемость) для данного сегмента керна.

При проведении исследования авторами активно использовались открытые библиотеки Python для машинного обучения и обработки данных Google TensorFlow [9], Keras [10], PIL [11], NumPy [12], Scikit-Learn [13] и OpenCV [14]. Для повышения точности работы нейронной сети и уменьшения риска переобучения был применен алгоритм Dropout [15].

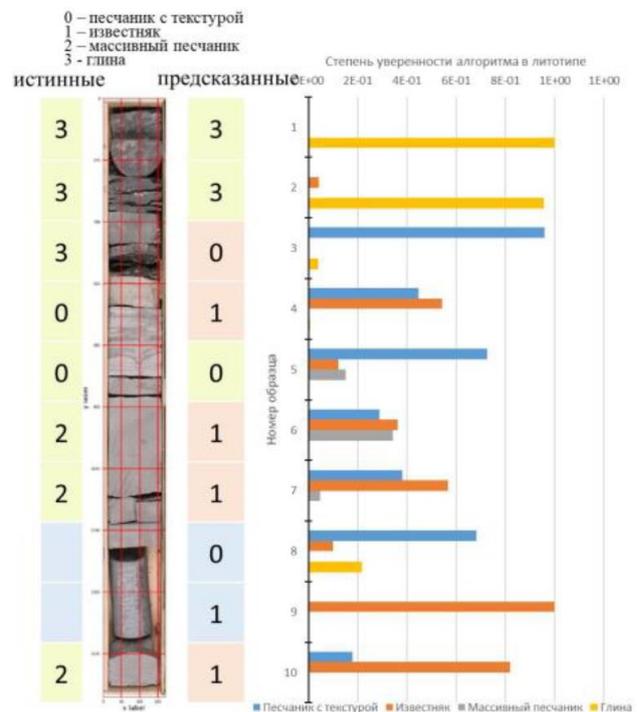


Рис. 4. Пример определения породы сегмента  
 Fig. 4. Example of determining a segment rock

Все это позволило авторам статьи написать глубокую сверточную нейронную сеть, для которой производились различные эксперименты с глубиной сети, количеством нейронов на слоях, функциями распространения ошибок и размерами изобра-

жений. Для обучения нейронной сети было использовано 800 изображений, приведённых к размеру 512×512 пикселей, составляющих 6 классов. В качестве обучающей выборки было использовано 60 % собранного материала и, соответственно, 40 % составляла тестовая выборка. Результаты, как говорят авторы статьи, показали до 96 % точности и 98 % полноты. Однако на некоторых классах (известняк, 124 образца) результаты падают до 42 % точности.

Несмотря на показанные в работе возможности использования нейронной сети для определения литотипов образцов керна, разработанный алгоритм имеет определенные недостатки, а именно: недостаточную обучающую выборку, неравномерность количества литотипов в обучающей выборке (сеть обрабатывает лишь 4 класса пород), низкую точность предсказаний для определенных классов пород.

Таким образом, нейросеть работает с большой точностью лишь при соблюдении ряда обязательных условий. Отдельно стоит упомянуть, что данная сеть выполняет описание керна не послойно, а с заданным шагом, что сильно влияет на результаты.

В работе [16] рассматривается создание инструмента предобработки и анализа фотографий керна. При этом важная роль отводится восстановлению поврежденных участков образца керна. Известно, что такие повреждения даже с учетом восстановления их при помощи заливки на основе окружения дают ощутимые погрешности при обучении нейросети.

Разработанная авторами статьи нейросеть позволяет выделить участки слоистости керна, а также получить информацию о положении границ выделенных участков керна – их глубины и видимые углы падения. При этом в обучающей выборке присутствовали, в том числе, образцы с поврежденными участками вследствие отбора из них проб.

Таким образом, в ходе работы была построена система, которая позволяет ускорить описание образцов керна специалистом-геологом. Другими словами, нейросеть сама не проводит анализ, а упрощает в дальнейшем проведение анализа человеком-оператором.

Также интересные результаты получены в [17], где определялась принадлежность слоев керна к одному из 4 типов пород: угли, песчаники, алевролиты и аргиллиты.

Выбор пород был обоснован тем, что данные 4 типа наиболее часто встречаются в обучающей выборке. Таким образом, авторы старались сделать распределение пород по классам более равномерным.

В качестве обучающей выборки авторами была использована база из 2,5 тыс. изображений пород при дневном свете. К этим изображениям также прилагалось послойное описание. Эти данные были взяты из 8 месторождений (около 15 скважин) Тюменской свиты. В итоге количество слоев составило порядка 4,4 тыс.

Особенность данной работы заключается в том, что для каждого слоя керн нарезался на квадраты 5×5 см с определенным шагом смещения в зависимости от одного из 4 типов пород. Такой прием позволил авторам сократить ошибку, вызванную неравномерным распределением пород в обучающей выборке, посредством увеличения шага для чаще встречающейся породы в выборке.

Для проведения исследований были взяты два широко используемых способа машинного обучения: на основе графических идентификаторов и на основе сверточных нейронных сетей.

В процессе эксперимента были использованы архитектуры следующих предварительно обученных нейронных сетей: SqueezeNet1.1, DenseNet121, DenseNet161, Inception-v3, ASNetLarge, PNASNet5Large, ResNet18, ResNet34, ResNet152, ResNeXt101 64×4d, ResNeXt101 32×4d, SENet154, VGG13, VGG16bn, VGG19bn.

На основании полученных результатов были сделаны выводы о вполне приемлемой точности обеих моделей, что позволяет говорить о целесообразности их использования на практике. В то же время модель на базе нейронных сетей оказалась более чувствительна к неявным признакам, которые трудно извлечь, применяя графические идентификаторы.

Однако стоит отметить, что обучающая выборка состояла из образцов, взятых из одной свиты (Тюменской), что, несомненно, влияет на качество результатов при использовании моделей на других свитах. Еще одним фактором является то, что в сравнении с, например, работой [8], в работе [17] были выделены лишь 4 класса.

### **Анализ цветности пород по цифровым изображениям керна**

Еще одним интересным и важным применением компьютерного анализа данных для решения задач классификации пород является анализ цветности по цифровым изображениям керна. В этом направлении значительное место занимают работы И.И. Хасанова [18–20], посвященные полуавтоматической обработке фотографий керна горных пород. В его работах напрямую не используются методы машинного обучения, а применяются экспертные системы на основе цветности изображения.

Так, в работе [19] И.И. Хасанов описывает разработанное им программное обеспечение, которое

делит процесс анализа керн на три этапа. На первом этапе происходит фотографирование образцов керн согласно определенному регламенту, в котором указаны параметры съемки, температура накаливания, вид ламп и особенности самой процедуры. Кроме того, при съемке керн используются таблицы эталонных цветов.

На втором этапе ПО на основании загруженных фотографий делит каждый образец на ячейки заданного размера и по ним строит таблицу с усредненными для каждой ячейки параметрами. В этой таблице высчитываются такие показатели, как значения цвета в схемах RGB или HSL. Кроме того, на данном этапе строится колонка средних цветов по скважине, а также определяются коэффициенты расчлененности и неоднородности.

На третьем этапе происходит выбор интервала скважины, который будет анализироваться, задание исходных параметров, представление и визуализация результатов.

Если сформулировать основную особенность данного приложения, то оно работает по типу экспертной системы – то есть изображение преобразуется в матрицы в различных цветовых схемах (RGB или HSL), после чего каждому классу цвета оператором присваивается та или иная характеристика породы (пористость, проницаемость и т. д.), присущая этому цвету, и ее литотип. Далее исследуются вариации параметров отдельных цветов и гистограмма распределения этих цветов. Стоит отметить, что исследование предусматривает обработку изображений, полученных как при дневном свете, так и при ультрафиолетовом.

Основными преимуществами данной работы являются:

- внимание к таким деталям, как процесс съемки образцов керн и наличие четкого регламента для съемки;
- использование помимо дневных УФ-фотографий;
- сопоставление результатов работы ПО с данными ГИС и петрофизическими исследованиями скважин.
- К недостаткам, на наш взгляд, можно отнести следующее:
- необходимость активного привлечения к работе специалиста-геолога для формирования базы знаний;
- наличие человеческого фактора как при задании параметров при работе с системой, так и при формировании базы знаний;
- разбиение на интервалы и усреднение показателей, что может привести к тому, что какая-то порода будет не определена, или ни одна из пород в этом сегменте не будет определена верно;
- отсутствие влияния структуры керн, так как один лишь цвет породы далеко не всегда может

служить надежным источником информации о литотипе;

- отсутствие влияния различных внешних факторов, таких как биологические включения, наличие элементов, привнесенных в процессе бурения/извлечения керн.

Близкий к рассмотренному в работе Хасанова подход описан в [21]. Здесь цветность и тип породы анализируются аналогично. Так, для каждого образца породы формируются его цветовые характеристики. Затем подвергается анализу вся скважина, на основании чего составляется литологическая колонка, размеченная по цвету. Определяются граничные значения цветов, которые соответствуют различным литотипам. Недостатки работы [21] во многом совпадают с недостатками в работе [19].

В работе [22] исследуются образцы керн, сфотографированные при дневном свете в высоком разрешении. Недостающие части керн на фотографиях (к примеру, изъятые образцы в виде цилиндрических проб) заполняются согласно окружающим текстуре и структуре по методу многоточечной статистики (multipoint statistics – MPS), что, естественно, уменьшает точность. Основным недостатком работы является проведение сравнения с библиотекой образцов путём выделения в явном виде таких параметров, как контрастность, интенсивность пикселей, что не является объективным описанием горных пород и зависит от условий съёмки. Также отсутствует описание изображений, сделанных при ультрафиолетовом освещении.

Таким образом, проведенный анализ основных методов и подходов в области классификации пород на образцах керн позволяет сделать следующие выводы:

- одним из основных недостатков большей части работ является неравномерность обучающей выборки. При определении типа породы обучающая выборка состоит из пород преимущественно одного или нескольких литотипов, или и вовсе анализируются не все литотипы; выборка же по остальным литотипам искусственно увеличена;
- во многих работах не рассматриваются изображения образцов керн в ультрафиолетовом свете, хотя ультрафиолетовое свечение позволяет выделять на изображениях нефтенасыщенные участки. Выделение таких участков позволяет говорить о наличии флюида на том или ином интервале;
- почти все рассмотренные работы сосредоточены на том, чтобы определить тип породы, причем чаще всего на основании цветности. Однако стоит принять во внимание, что съемка без наличия палитры может дать искажения цвета (исключением являются работы [18–20]). Тогда

такие изображения не позволят достоверно определить литотип по цветности. Кроме того, цветность пород ввиду различных явлений может различаться;

- в некоторых работах при определении типа породы используется либо фиксированный, либо настраиваемый шаг по изображению керна. При таком методе, если в диапазоне одного шага будут находиться несколько пород, система не сможет выделить их, что в конечном итоге приведет к неверному результату;
- часть рассмотренных решений не позволяет производить полную автоматизацию, а лишь упрощает в некоторой степени работу специалиста-геолога.

Кроме того, во всех рассмотренных работах задача классификации выполнялась примерно одинаково. На изображении с несколькими образцами керна обрезался конкретный образец, причем неровности, края образца, тоже обрезались. Далее выбирался размер окна, и обрезанный керн, согласно этим размерам, делился на интервалы. Исследования проводились отдельно внутри каждого интервала, в результате чего определялся тип породы в интервале. Такой алгоритм классификации имеет существенные недостатки, так как:

- рассматривается не весь образец керна;
- требуется ручная обрезка каждого образца;
- в анализируемом интервале определяется только одна порода, хотя в нем может находиться и большее число пород.

### Направление развития методов классификации пород на образцах керна Алгоритм сегментации на основе сверточных нейронных сетей

Как показано выше, одним из ключевых факторов, который влияет на качество классификации керна по литотипам, является исходный материал, для которого выполняются исследования. Поэтому первым шагом развития методов классификации является сегментация образцов керна. Это позволит значительно сократить трудозатраты, связанные с ручной обрезкой образцов керна, а также сделает анализ более точным, так как будут учитываться неровности керна, которые ранее при использовании нейронной сети обрезались (рис. 5).

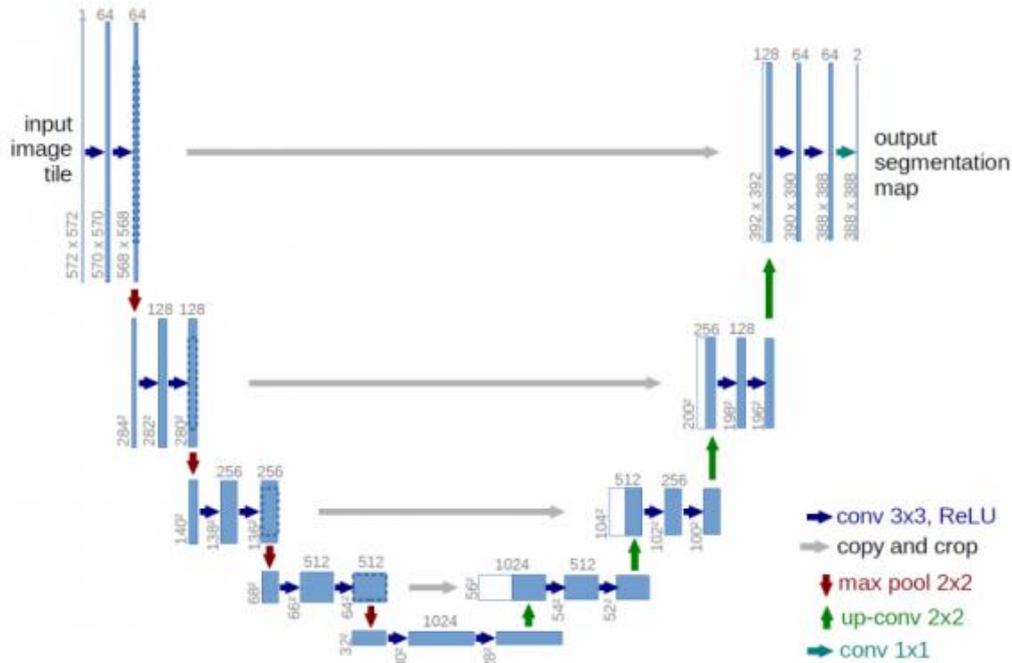
Кроме того, при наличии сильно раздробленных образцов (рис. 6) обрезать их так, чтобы исключить влияние коробки, в которой они лежат, становится крайне трудоемкой и долгой задачей. Сегментация керна решает и эту проблему.



Рис. 5. Части керна, которые не учитываются при обрезке  
Fig. 5. Parts of the core that are not taken into account when trimming



Рис. 6. Пример раздробленных образцов керна для анализа  
Fig. 6. Example of crushed core samples for analysis



**Рис. 7.** Архитектура сети U-Net  
**Fig. 7.** U-Net network architecture

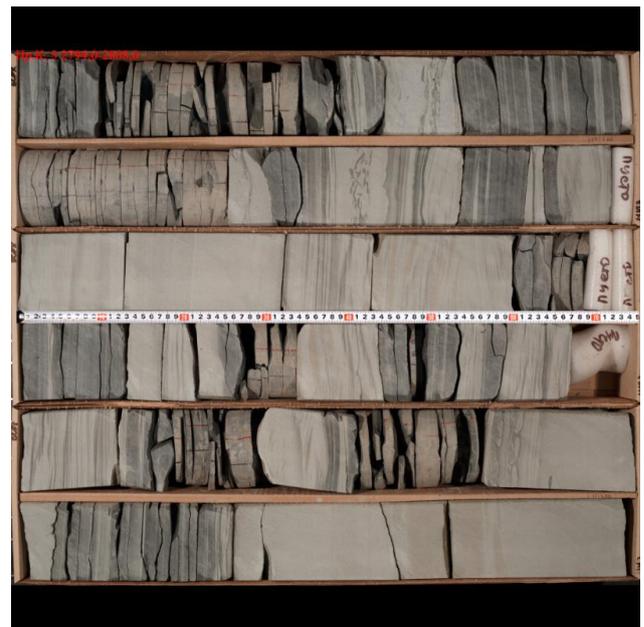
Для реализации алгоритма сегментации была выбрана свёрточная нейронная сеть с архитектурой U-Net, поскольку это достаточно простая и типичная архитектура нейронной сети, способная распознавать объекты на изображениях. В дальнейшем развитии работы возможно применение более продвинутых и сложных моделей, таких как ResNet и GoogleNet. Архитектура сети U-Net приведена на рис. 7. Она состоит из сужающегося пути (слева) и расширяющегося пути (справа). Сужающийся путь – типичная архитектура сверточной нейронной сети.

В ходе работы использовались реальные фотографии керн с разрешением 4000×4000 пикселей. Перед проведением вычислительного эксперимента были сформулированы следующие требования:

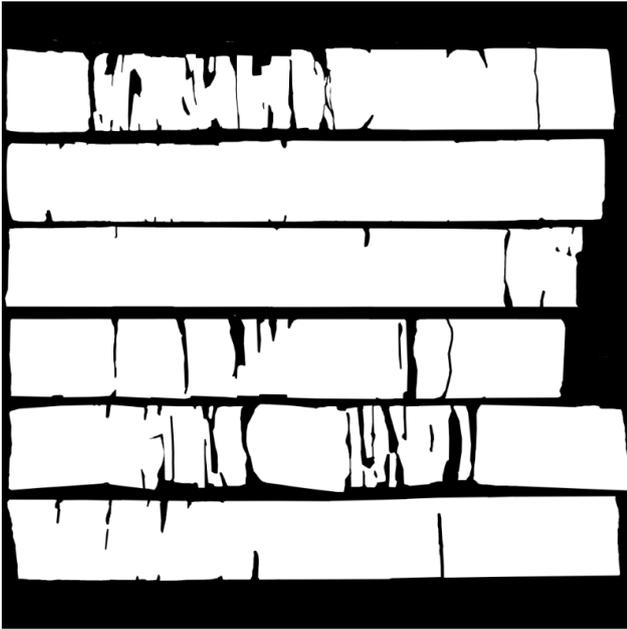
- для более полного анализа использовать ультрафиолетовые фотографии;
- выбирать изображения высокого качества;
- применять алгоритм Dropout [15];
- использовать более широкий класс пород на скважинах, с которых отбирается керн.

Однако в ходе эксперимента для того, чтобы избежать проблем с неоднородными образцами [23], корректного наложения ультрафиолетовых фотографий и более эффективного обучения сети, было принято решение первоначально выполнить сегментацию образцов керн на дневных изображениях. На первом этапе сегментации производилось обучение нейронной сети распознавать, где на фотографии находится порода, и где прочие объекты.

На основе каждой фотографии в обучающем наборе с использованием средств Photoshop была создана бинарная маска (содержащая строго два цвета – чёрный и белый), где чёрный цвет – отсутствие породы, белый – её наличие. На рис. 8, 9, соответственно, представлены фотография керн для обучения U-Net и маска фотографии керн.



**Рис. 8.** Фотография керн для обучения U-Net  
**Fig. 8.** Photo of core for U-Net training



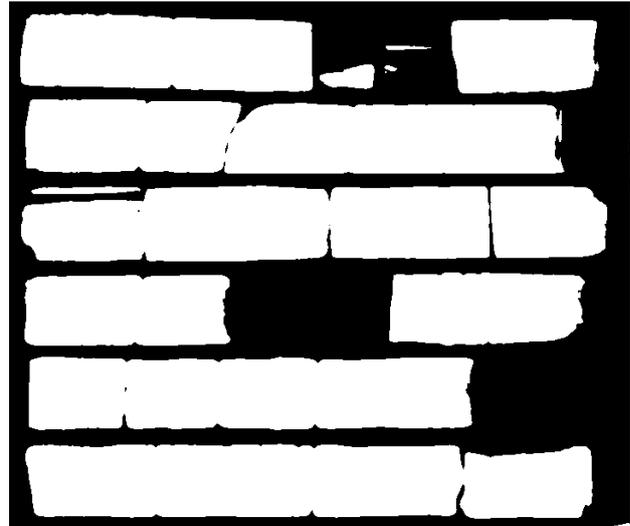
**Рис. 9.** Маска фотографии ядра  
**Fig. 9.** Core photography mask

С учётом того, что на одной фотографии находится в среднем пять образцов ядра (на некоторых может быть два, на других шесть) по 3 м каждый, суммарный объем обучающей выборки составлял около 900 м ядра. Тестовая выборка, предназначенная для сегментирования нейронной сетью, содержала примерно 180 м ядра, что составляет 20 % от обучающей выборки. Нейронная сеть была обучена два раза: на 450 м ядра с проходом 10 эпох и на 900 м ядра с проходом 20 эпох.

В качестве примера на рис. 10, 11 представлены тестовая фотография и результат сегментации для модели, представляющей 900 м ядра с проходом 20 эпох.



**Рис. 10.** Тестовая фотография ядра  
**Fig. 10.** Core test photo



**Рис. 11.** Результат сегментации  
**Fig. 11.** Segmentation result

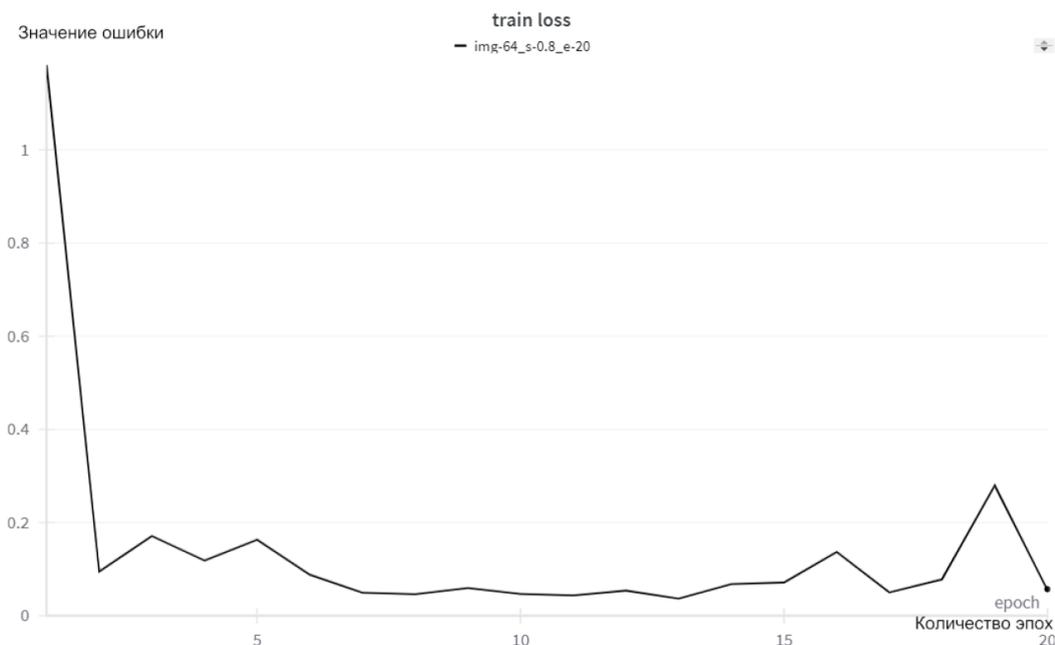
Из сопоставления рисунков видно, что все ровные участки размечены правильно, однако раздробленные участки ядра нейронная сеть не распознаёт как породу. Это говорит о том, что нейронная сеть при сегментации ориентируется не только на цвет, но и на форму, при этом она обучена распознавать только ровные образцы, из-за чего раздробленные примеры размечает как посторонние объекты. Это говорит о необходимости обучения нейронной сети не только на ровных, но и на раздробленных образцах породы.

Для количественной оценки качества сегментации была рассчитана функция потерь, которая показана на рис. 12.

Из приведенного рисунка видно, что с ростом эпох ошибка уменьшается и уже после 7–8 эпохи принимает достаточно малые значения. Однако стоит отметить, что функция потерь была рассчитана для примеров из обучающей выборки, а для модели на тестовых изображениях она может иметь более высокие значения, так как нейронная сеть не была обучена на раздробленных образцах породы.

### Заключение

Проведен анализ существующих методов и подходов к решению задачи классификации пород на образцах ядра. Рассмотрено применение методов машинного обучения и компьютерный анализ цветности пород. Показано, что в большинстве работ основное внимание уделено обработке фотографий ядра, полученных в дневном свете. При этом хорошо известно, что ультрафиолетовое свечение позволяет выделять на изображениях нефтенасыщенные участки, которые говорят о наличии флюида в рассматриваемом интервале.



**Рис. 12.** График функции потерь  
**Fig. 12.** Loss function graph

Также следует отметить, что в ряде работ при определении типа породы используют либо фиксированный, либо настраиваемый шаг по изображению зерна, что позволяет в пределах одного интервала глубин выделить только одну породу, хотя на самом деле там может находиться несколько пород. Еще одним недостатком рассмотренных методов является удаление неровностей зерна, которые при использовании машинных методов анализа, в том числе применения нейронных сетей, обрезались. Все это позволило разработать план и требования к проведению дальнейшего исследования образцов зерна средствами машинного обучения. При этом было показано, что первым шагом развития методов классификации образцов зерна должна являться сегментация изображений.

В результате с применением сверточной нейронной сети на архитектуре U-Net была обучена

модель для решения задачи сегментации образцов зерна на дневных изображениях и приведены результаты работы модели, которые показали вполне приемлемую точность распознавания породы и прочих объектов.

В дальнейшем планируется обучение моделей на основе других архитектур сверточных нейронных сетей и проведение сравнительного анализа, расширение обучающей выборки для улучшения качества сегментации на неоднородных образцах породы, сравнение результатов работы модели с объединёнными выборками монолитного и раздробленного зерна и с разъединёнными выборками, на которых модель обучается отдельно, а также решение задач сегментации образцов зерна на ультрафиолетовых изображениях для определения нефтенасыщенных интервалов.

## СПИСОК ЛИТЕРАТУРЫ

1. Особенности изучения фильтрационных характеристик ориентированного зерна сложнопостроенных карбонатных коллекторов / И.П. Гурбатова, В.В. Плотников, Н.А. Попов, И.В. Сысоев // Вестник ПНИПУ. Геология. Нефтегазовое и горное дело. – 2013. – № 9. – С. 79–86.
2. Informational technologies of processing and interpretation of data for surface and in wells seismic observations for solving of tasks of geological section prognosis / V.P. Ivanchenkov, O.N. Vylegzhanin, O.V. Orlov, A.I. Kochegurov // Proc. 9th Russian–Korean International Symposium on Science and Technology. KORUS–2005. – Novosibirsk, 2005. – Vol. 1. – P. 159–162.
3. Иванченков В.П., Кочегуров А.И., Орлов О.В. Применение методов фазочастотного анализа сейсмических волн для изучения околоскважинного пространства // Нефтяное хозяйство. – 2015. – № 10. – С. 58–63.
4. Kochegurov A.I., Kochegurova E.A., Kupina N.A. Detection accuracy of the temporary state of complex signals using phase-frequency tracking methods with equilibrium and non-equilibrium processing // Advances in Intelligent Systems and Computing. – 2015. – Vol. 342. – P. 27–36.
5. Patel A.K., Snehomoy C. Computer vision-based limestone rock-type classification using probabilistic neural network // Geoscience Frontiers. – 2016. – № 7. – P. 53–60.
6. Design and development of a machine vision system using artificial neural network-based algorithm for automated coal characterization / A.G. Gorai, S. Raval, A.K. Patel, C. Snehomoy, T. Gautam // International Journal of Coal Science & Technology. – 2020. – № 8. – P. 737–755.

7. Patel A., Snehomoy C., Gorai A.K. Development of online machine vision system using support vector regression (SVR) algorithm for grade prediction of iron ores // Fifteenth IAPR International Conference on Machine Vision Applications (MVA). – Nagoya, 2017. – P. 149–152.
8. Литологическая интерпретация фотографий ядра на основе компьютерного анализа / А.В. Ивченко, Е.Е. Барабошкин, Л.С. Исмаилова и др. // IEEE Northwest Russia Conference On Mathematical Methods In Engineering And Technology: MMET NW 2018: Международная научная конференция. – СПб: СПбГЭТУ «ЛЭТИ», 2018. – С. 430–433.
9. Введение в TensorFlow // TensorFlow. URL: <https://www.tensorflow.org/learn?hl=ru> (дата обращения: 06.10.2023).
10. Keras. Get Started // Keras. URL: <https://keras.io/> (дата обращения: 06.10.2023).
11. Pillow (PIL Fork) 10.4.0 documentation // Pillow. 2024. URL: <https://pillow.readthedocs.io/en/stable/> (дата обращения: 03.10.2023).
12. NumPy 1.26.0 released // NumPy. 2024. URL: <https://numpy.org/> (дата обращения: 03.10.2023).
13. Scikit-Learn. Getting Started // Scikit-Learn. Machine Learning in Python. URL: [https://scikit-learn.org/stable/getting\\_started.html](https://scikit-learn.org/stable/getting_started.html) (дата обращения: 28.09.2023).
14. OpenCV. Modules // Open-Source Computer Vision. URL: <https://docs.opencv.org/4.x/> (дата обращения: 27.09.2023).
15. Dropout – метод борьбы с переобучением нейронной сети // Введение в нейронные сети, 2024. URL: [https://progorprogs.ru/neural\\_network/dropout-metod-borby-s-pereobucheniem-neuronnoy-seti](https://progorprogs.ru/neural_network/dropout-metod-borby-s-pereobucheniem-neuronnoy-seti) (дата обращения: 24.09.2023).
16. Артамонов В.П., Каюров Н.К. Автоматизация алгоритмов предобработки и анализа фотографий ядра для целей процесса макро- и литологического описания // Интеллектуальный анализ данных в нефтегазовой области: Тезисы докладов 3 научно-практической конференции. – Новосибирск, 2022. URL: <https://libgeo.ru/library/data-science?filter=302> (дата обращения: 24.09.2023).
17. Дьячков С.М. и др. Автоматическое определение породы по фотографиям ядра современными методами машинного обучения // Вестник Тюменского государственного университета. Серия: Физико-математическое моделирование. Нефть, газ, энергетика. – 2021. – Т. 7. – № 4 (28). – С. 181–198.
18. Новые методические аспекты литологических исследований пород баженовской свиты / А.В. Постников, О.В. Постникова, К.Ю. Оленова, И.И. Хасанов и др. // Нефтяное хозяйство. – 2015. – № 10. – С. 23–27.
19. Хасанов И.И. Анализ цветности пород по цифровым изображениям ядра // Геология нефти и газа. – 2014. – № 5. – С. 33–39.
20. Khasanov I. The use of computer analysis of digital images for the study of core material // Geomodel 2015: 17th science and applied research conference on oil and gas geological exploration and development. – 2015. – Vol. 2015. – P. 1–5.
21. Patent USA № US8416413B2, 09.04.2013. Products and methods for identifying rock samples.
22. Patent USA № US2017286802, 2017. Automated core description.
23. Изучение и анализ современных подходов к построению цифровых моделей ядра и методов моделирования многофазной фильтрации в масштабах порового пространства / К.М. Герке, Д.В. Корост, М.В. Карсанина, С.Р. Корост и др. // Георесурсы. – 2021. – Т. 23. – № 2. – С. 197–213.

### Информация об авторах

**Александр Иванович Кожегуров**, кандидат технических наук, доцент отделения информационных технологий Инженерной школы информационных технологий и робототехники Национального исследовательского Томского политехнического университета, Россия, 634050, г. Томск, пр. Ленина, 30. kaicc@tpu.ru, <https://orcid.org/0000-0003-4473-528X>

**Владислав Игоревич Денисов**, аспирант Национального исследовательского Томского политехнического университета, Россия, 634050, г. Томск, пр. Ленина, 30. iornet.dv@gmail.com

**Елизавета Александровна Задорожных**, студент Национального исследовательского Томского политехнического университета, Россия, 634050, г. Томск, пр. Ленина, 30. eaz28@tpu.ru

Поступила в редакцию: 02.08.2024

Поступила после рецензирования: 10.08.2024

Принята к публикации: 09.09.2024

### REFERENCES

1. Gurbatova I.P., Plotnikov V.V., Popov N.A., Sysoev I.V. Features of studying the filtration characteristics of oriented cores of complex carbonate reservoirs. *Bulletin of PNIPU. Geology. Oil and gas and mining*, 2013, no. 9, pp. 79–86. (In Russ.)
2. Ivanchenkov V.P., Vylegzhanin O.N., Orlov O.V., Kochegurov A.I. Informational technologies of processing and interpretation of data for surface and in wells seismic observations for solving of tasks of geological section prognosis. *Proc. 9<sup>th</sup> Russian–Korean International Symposium on Science and Technology. KORUS–2005*. Novosibirsk, 2005. Vol. 1, pp. 159–162.
3. Ivanchenkov V.P., Kochegurov A.I., Orlov O.V. Methods of phase-frequency analysis of seismic waves and their application in studying borehole environment. *Neftyanoe khozyaystvo – Oil Industry*, 2015, no. 10, pp. 58–63. (In Russ.)
4. Kochegurov A.I., Kochegurova E.A., Kupina N.A. Detection accuracy of the temporary state of complex signals using phase-frequency tracking methods with equilibrium and nonequilibrium processing. *Advances in Intelligent Systems and Computing*, 2015, vol. 342, pp. 27–36.
5. Patel A.K., Snehomoy C. Computer vision-based limestone rock-type classification using probabilistic neural network. *Geoscience Frontiers*, 2016, no. 7, pp. 53–60.

6. Gorai A.G., Raval S., Patel A.K., Snehamoy C., Gautam T. Design and development of a machine vision system using artificial neural network-based algorithm for automated coal characterization. *International Journal of Coal Science & Technology*, 2020, no. 8, pp. 737–755.
7. Patel A., Snehamoy C., Gorai A.K. Development of online machine vision system using support vector regression (SVR) algorithm for grade prediction of iron ores. *Fifteenth IAPR International Conference on Machine Vision Applications (MVA)*. Nagoya, 2017. pp. 149–152.
8. Ivchenko A.V., Baraboshkin E.E., Ismailova L.S. and others. Lithological interpretation of core photographs based on computer analysis. *International scientific conference. IEEE Northwest Russia Conference on Mathematical Methods in Engineering and Technology: MMET NW 2018*. St. Petersburg, SPbSETU "LETI" Publ., 2018. pp. 430–433. (In Russ.)
9. *Introduction in TensorFlow*. (In Russ.) Available at: <https://www.tensorflow.org/learn?hl=ru> (accessed 6 October 2023).
10. *Keras. Get Started*. Available at: <https://keras.io/> (accessed 6 October 2023).
11. *Pillow (PIL Fork) 10.1.0 documentation*. Available at: <https://pillow.readthedocs.io/en/stable/> (accessed 3 October 2023).
12. *NumPy 1.26.0 released*. NumPy. Available at: <https://numpy.org/> (accessed 3 October 2023).
13. *Scikit-Learn. Getting Started*. Scikit-Learn. *Machine Learning in Python*. Available at: [https://scikit-learn.org/stable/getting\\_started.html](https://scikit-learn.org/stable/getting_started.html) (accessed 28 September 2023).
14. *OpenCV. Modules*. Open-Source Computer Vision. Available at: <https://docs.opencv.org/4.x/> (accessed 27 September 2023).
15. *Dropout – a method for combating neural network overtraining*. *Introduction to neural networks*. (In Russ.) Available at: [https://proproprogs.ru/neural\\_network/dropout-metod-borby-s-pereobucheniem-neyronnoy-seti](https://proproprogs.ru/neural_network/dropout-metod-borby-s-pereobucheniem-neyronnoy-seti) (accessed 24 September 2023).
16. Artamonov V.P., Kayurov N.K. Automation of algorithms for preprocessing and analysis of core photographs for the purposes of the process of macro- and lithological description. *Abstracts of reports of the 3<sup>rd</sup> scientific and practical conference Intelligent data analysis in the oil and gas field*. Novosibirsk, 2022. (In Russ.) Available at: <https://libgeo.ru/library/data-science?filter=302> (accessed 24 September 2023).
17. Dyachkov S.M. Automatic determination of rock from core photographs using modern machine learning methods. *Bulletin of Tyumen State University. Series: Physical and mathematical modeling. Oil, gas, energy*, 2021, vol. 7, no. 4 (28), pp. 181–198. (In Russ.)
18. Postnikov A.V., Postnikova O.V., Olenova K.Yu., Khasanov I.I. New methodological aspects of lithological research of rocks of the Bazhenov formation. *Neftyanoe khozyaystvo – Oil Industry*, 2015, no. 10, pp. 23–27. (In Russ.)
19. Khasanov I.I. Analysis of rock color using digital core images. *Geology of Oil and Gas*, 2014, no. 5, pp. 33–39. (In Russ.)
20. Khasanov I. The use of computer analysis of digital images for the study of core material. *Geomodel 2015. 17<sup>th</sup> science and applied research conference on oil and gas geological exploration and development*, 2015, vol. 2015, pp. 1–5.
21. Ellington W.E., Moore J.C., Smith M.A. *Products and methods for identifying rock samples*. US Patent no. US8416413B2, 2013.
22. Mezghani M.M., Shammari S.H., Anifowose F.A. *Automated core description*. US Patent no. US2017286802, 2017.
23. Gerke K.M., Korost D.V., Karsanina M.V., Korost S.R. Modern approaches to pore space scale digital modeling of core structure and multiphase flow. *Georesursy*, 2021, vol. 23, no. 2, pp. 197–213.

#### Information about the authors

**Alexander I. Kochegurov**, Cand. Sc., Associate Professor, National Research Tomsk Polytechnic University, 30, Lenin avenue, Tomsk, 634050, Russian Federation. [kaicc@tpu.ru](mailto:kaicc@tpu.ru), <https://orcid.org/0000-0003-4473-528X>

**Vladislav I. Denisov**, Postgraduate Student, National Research Tomsk Polytechnic University, 30, Lenin avenue, Tomsk, 634050, Russian Federation. [10rnet.dv@gmail.com](mailto:10rnet.dv@gmail.com)

**Elizaveta A. Zadorozhnykh**, Student, National Research Tomsk Polytechnic University, 30, Lenin avenue, Tomsk, 634050, Russian Federation. [ezaz28@tpu.ru](mailto:ezaz28@tpu.ru)

Received: 02.08.2024

Revised: 10.08.2024

Accepted: 09.09.2024