

УДК 550.834
Шифр специальности ВАК: 1.2.1, 1.6.11
DOI: 10.18799/24131830/2025/10/5261
Научная статья



Гибридный алгоритм определения нефтенасыщенности керна по макрофотографиям пород в дневном и ультрафиолетовом свете

А.И. Кочегуров, В.И. Денисов✉, Н.Е. Семенченко, Е.А. Андренкова

Национальный исследовательский Томский политехнический университет, Россия, г. Томск

✉l0rnet.dv@gmail.com

Аннотация. Актуальность. Анализ керна – это основа для изучения нефтегазовых пластов. Но обычные способы исследования керна, особенно оценка нефтенасыщенности по УФ-свечению, очень трудозатратны, зависят от человека и не имеют четких правил. Данных с месторождений становится все больше, что усугубляет ситуацию. Поэтому нужны автоматические, объективные и масштабируемые методы. **Цель.** Разработка гибридного алгоритма определения нефтенасыщенности керна по макрофотографиям пород в дневном и ультрафиолетовом свете и его программная реализация. **Методы.** Обработки изображений, компьютерного зрения и глубокого обучения. Для классификации УФ-свечения была предложена мультимодальная модель на основе ResNet-34. Она обрабатывает сразу шесть каналов: RGB обычного света + RGB УФ-света. Программная реализация выполнена в виде интеллектуальной информационной системы на основе микросервисной архитектуры. **Результаты.** Разработан алгоритм классификации УФ-свечения, который показал точность 90 % для типа свечения и 80 % для его интенсивности. Разработана интеллектуальная информационная система, которая реализует полученный гибридный алгоритм, обрабатывает большие фото (4000×4000 пикселей) и сокращает место для хранения на 20–40 %, потому что хранит только нужные сегментированные части изображений. **Выводы.** Использованный подход, объединяющий анализ разных типов изображений и гибкую систему на микросервисах, является перспективным. Он не только автоматизирует и делает объективной оценку нефтенасыщенности, но и создает основу для будущих разработок в цифровой петрофизике. Решение помогает точнее определять насыщенность, быстрее анализировать данные и экономить место для хранения, что имеет высокую практическую значимость для нефтегазовой отрасли.

Ключевые слова: анализ керна, нефтенасыщенность, машинное обучение, компьютерное зрение, U-Net, ResNet, мультимодальный анализ, УФ-флуоресценция, микросервисная архитектура, цифровая петрофизика

Для цитирования: Кочегуров А.И., Денисов В.И., Семенченко Н.Е., Андренкова Е.А. Гибридный алгоритм определения нефтенасыщенности керна по макрофотографиям породы в дневном и ультрафиолетовом свете // Известия Томского политехнического университета. Инжиниринг георесурсов. – 2025. – Т. 336. – № 10. – С. 28–37. DOI: 10.18799/24131830/2025/10/5261

UDC 550.834
DOI: 10.18799/24131830/2025/10/5261
Scientific paper



Hybrid algorithm for determining core oil saturation from rock macro-photographs in daylight and ultraviolet light

A.I. Kochegurov, V.I. Denisov✉, N.E. Semchenko, E.A. Andrenkova

National Research Tomsk Polytechnic University, Tomsk, Russian Federation

✉l0rnet.dv@gmail.com

Abstract. Relevance. Core sample analysis is fundamental for studying oil and gas reservoirs. However, conventional core investigation methods – especially UV fluorescence-based oil saturation assessment – are highly labor-intensive, human-dependent, and has no clear guidelines. Increasing volumes of field data exacerbate this issue, necessitating automated, objec-

tive, and scalable solutions. **Aim.** To develop a hybrid algorithm for determining core oil saturation using macro-photographs of rocks in daylight and ultraviolet light, along with its software implementation. **Methods.** Image processing, computer vision, and deep learning methods. For UV fluorescence classification, we proposed a multimodal model based on ResNet-34. It processes six channels simultaneously: RGB daylight + RGB UV light. The software was implemented as an intelligent information system using a microservice architecture. **Results.** We developed a UV fluorescence classification algorithm achieving 90% accuracy in identifying fluorescence type and 80% accuracy in intensity assessment. The implemented intelligent information system processes high-resolution images (4000×4000 px) and reduces storage requirements by 20–40% by retaining only essential segmented image parts. **Conclusions.** The combined approach – integrating multi-image analysis and flexible microservices – appears promising. It not only automates and objectifies oil saturation assessment but also establishes a foundation for future digital petrophysics research. This solution enables more accurate saturation determination, faster data analysis, and optimized storage, which could benefit the oil and gas industry.

Keywords: core analysis, oil saturation, machine learning, computer vision, U-Net, ResNet, multimodal analysis, UV fluorescence, microservice architecture, digital petrophysics

For citation: Kochegurov A.I., Denisov V.I., Semenchenko N.E., Andrenkova E.A. Hybrid algorithm for determining core oil saturation from rock macro-photographs in daylight and ultraviolet light. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*, 2025, vol. 336, no. 10, pp. 28–37. DOI: 10.18799/24131830/2025/10/5261

Введение

Исследование образцов керна (породы, извлеченной при бурении) – это основа для изучения нефтегазовых месторождений. Анализ керна помогает определить самые важные свойства пород (как они пропускают и удерживают флюиды), их состав и строение. Эти данные нужны, чтобы спланировать разработку всего месторождения. Сейчас объемы геологоразведки растут, и керна для анализа становится все больше. Это создает проблему «больших данных»: хранение детальных фотографий керна требует значительного дискового пространства (сотни терабайт), а найти нужные образцы или подобрать похожие по заданным свойствам становится очень сложно [1].

Проблема не только в хранении, но и в самом анализе. Обычно керн описывается геологом вручную. Это долгий и трудоемкий процесс, и результаты могут зависеть от мнения специалиста [1]. Яркий пример такой задачи – оценка нефтенасыщенности по фотографиям в ультрафиолетовом (УФ) свете (люминесценции). Геолог сравнивает фотографии керна при обычном и УФ-свете, оценивая на глаз тип, характер и яркость свечения. Но, как отмечается в [2], до сих пор не существует единых четких правил для такой оценки. Из-за этого результаты анализа могут значительно различаться у разных специалистов, а сам анализ плохо повторяется. Это серьезная проблема для такого важного параметра.

Существующие полуавтоматические методы, основанные на простых алгоритмах (например, по порогу яркости или цвету), также не решают всех проблем. Они чувствительны к условиям съемки, требуют постоянной настройки экспертом и дают усредненные, неточные результаты для сложных образцов (неоднородных или раздробленных), теряя детали о форме фрагментов [3–14]. В итоге в нефтегазовой отрасли сейчас не хватает инстру-

ментов, которые могли бы ускорить анализ, повысить его точность и объективность, упростить хранение и поиск данных.

Использование методов машинного обучения (machine learning – ML) – логичный шаг для решения этих задач. Современные подходы, особенно глубокое обучение (Deep Learning), могут автоматически находить сложные признаки на изображениях, иногда даже превосходя человека в специфических случаях. Применение ML для анализа керна уже показывает хорошие результаты в задачах определения типа породы (литологии) и прогноза свойств породы. Однако большинство существующих работ [3–14] либо решают очень узкие задачи, либо не предлагают готового решения, которое можно внедрить в реальный производственный процесс.

Целью данной работы является создание гибридного алгоритма для определения нефтенасыщенности керна по его детальным фотографиям в обычном и УФ-свете.

Работа состоит из двух основных частей:

1. Разработка и валидация алгоритма машинного обучения для совместного анализа фотографий керна в обычном и УФ-свете.
2. Проектирование и реализация интеллектуальной информационной системы (ИИС) для внедрения этого алгоритма.

Для достижения поставленной цели были решены следующие задачи:

- разработка автоматизированного конвейера подготовки данных, объединяющего сегментацию изображений, распознавание метаданных и слияние с лабораторными отчетами;
- подготовка датасета для обучения модели классификации УФ-свечения;
- создание и валидация нейросетевой модели, работающей с двумя типами изображений (мультиспектральной и ультрафиолетовой).

тимодальной), для классификации характеристик УФ-свечения;

- проектирование и программная реализация ИИС на основе микросервисной архитектуры. Работа вносит вклад:
- в прикладное машинное обучение – предлагая новые подходы к анализу разных типов геологических данных (изображений);
- в инженерии программного обеспечения – демонстрируя архитектуру системы, которая эффективно работает с данными о породах.

Постановка задачи

На практике сотрудники лаборатории исследования кернa выполняют анализ макрофотографий кернa в дневном и ультрафиолетовом свете, результатом которого является отчет, пример которого представлен на рис. 1.

Необходимо построить гибридный алгоритм, который должен автоматизировать составление отчетов (рис. 1), а именно определять все данные, находящиеся в секции «Свечение»:

- Координаты начала и конца свечения на изображении
- Классификация типа свечения:
 - УВ – Углеводород
 - УВ + К – Углеводород (большая часть) совместно с карбонатом
 - К – Карбонат
 - К + УВ – Карбонат (большая часть) совместно с углеводородом
 - ФБР – Фильтрат бурового раствора
 - М – Свечение обусловлено минеральным составом
- Классификация характера свечения:
 - О – Однородный
 - НО – Неоднородный

- РМ – Равномерный
- НР – Неравномерный
- С – Слоистый
- ПНС – Переслаивание с ненасыщенными слоями
- ПКС – Переслаивание с карбонизированными слоями
- П – Пятнистый
- Л – Линзовидный
- Т – Текстурный (оползневый, биотурбационный, эрозионный)
- ТР – Трещинный
- Р – Редкий
- Классификация интенсивности свечения:
 - Низкая
 - Средняя
 - Высокая

Первым этапом разработки алгоритма является формирование датасета для обучения модели.

Подготовка датасета

Подготовка датасета для модели решаемой задачи, описанной выше, является весьма сложным процессом ввиду необходимости наложения данных об интервалах свечения на фотографии. На фотографии кернa требуется нанести интервалы свечения, отражающие значения кровли и подошвы пластов, при этом сами значения написаны на коробках с керном рукописным текстом.

Ключевой идеей получения датасета стала максимальная автоматизация всего цикла подготовки данных – от «сырых» снимков до получения конечных аналитических признаков. Для этого был создан автоматизированный конвейер подготовки данных, сокративший время ручного труда с 30 до 4 часов на тестовом наборе из 108 образцов.

Данные по керну					Пласт	Свечение				
№	Кровля, м	Подошва, м	Проходка, м	Вынос, %		Глубина от начала кернa, м	Мощность, м	Тип	Интенсивность	Характер
1	2995	3011	16	96	ЮС2**	2.14	0.53	К	Средняя	РВ
1	2995	3011	16	96	ЮС2**	5.21	0.04	УВ	Высокая	Л
1	2995	3011	16	96	ЮС2**	5.59	0.05	УВ	Высокая	Л
1	2995	3011	16	96	ЮС2**	6.13	0.45	К	Низкая	ПНС, Л
2	3011	3025	16	92	ЮС2**	10.91	0.01	М	Высокая	Л
4	3051	3068	16	79	ЮС3**	2.48	0.22	К	Средняя	ТР
4	3051	3068	16	79	ЮС3**	9.31	0.19	УВ	Низкая	НР
4	3051	3068	16	79	ЮС3**	10.58	0.11	УВ	Низкая	ТР
5	3068	3090	16	95	ЮС3**	1.45	1.68	УВ	Высокая	РВ, С
5	3068	3090	16	95	ЮС3**	3.51	1.26	УВ	Высокая	РВ
5	3068	3090	16	95	ЮС3**	5.68	0.19	УВ	Высокая	ПНС
5	3068	3090	16	95	ЮС3**	6.29	0.11	УВ	Высокая	ПНС
5	3068	3090	16	95	ЮС3**	6.8	0.05	УВ	Высокая	Л
5	3068	3090	16	95	ЮС3**	7.24	1.33	УВ	Высокая	РВ
5	3068	3090	16	95	ЮС3**	9.5	0.04	УВ	Высокая	Л
5	3068	3090	16	95	ЮС3**	9.77	0.05	УВ	Высокая	Л
6	3090	3098	12	95	ЮС3**	3.66	0.85	УВ	Высокая	ПНС

Рис. 1. Пример отчета по анализу образцов кернa

Fig. 1. Example of core sample analysis report

Конвейер включает следующие этапы:

1. Сегментация изображений.

На вход подается пара изображений (дневной и УФ-свет). Модифицированная нейросеть архитектуры U-Net [15, 16] обрабатывает дневное изображение и создает бинарную маску, точно очерчивающую контуры образца керна. Эта маска затем применяется к обоим изображениям.

Полученные образцы керна сохраняются в базе данных для дальнейшей работы.

2. Извлечение метаданных (optical character recognition – OCR)

Из дневного снимка автоматически извлекаются рукописные и печатные метки (номер керна, интервалы глубин). Для их распознавания используется технология EasyOCR, дополненная алгоритмами постобработки для коррекции ошибок.

После чего происходит расчет кровли и подошвы каждого образца керна в коробке, затем полученные данные сохраняются со связью на изображения образцов керна, выделенные на предыдущем шаге.

3. Слияние данных

Распознанные данные на этапах 1 и 2 используются в качестве ключа для объединения с лабораторными отчетами, содержащими петрофизические характеристики (рис. 1).

4. Формирование датасета

На выходе формируется структурированный набор данных, где каждому образцу соответствует пара сегментированных изображений (дневное и УФ) и набор метаданных, включая целевые классы для обучения.

Структура полученного датасета представлена на рис. 2.




Рис. 2. Пример структуры датасета

Fig. 2. Example of dataset structure

Конвейер реализован как часть интеллектуальной информационной системы, которая будет описана ниже, а сам датасет формируется за счет микросервиса для формирования отчетов.

Алгоритм анализа нефтенасыщенности на основе мультимодальных данных

Для классификации характеристик нефтенасыщенности была разработана модель на основе архитектуры ResNet-34 [17]. Данный подход реализует принцип раннего слияния (early fusion) мультимодальных данных.

Изображения в дневном и УФ-свете, предварительно приведенные к единому размеру, конкатенируются по каналному измерению, образуя единый шестиканальный тензор (RGB-день + RGB-УФ). Этот тензор подается на вход модифицированного первого сверточного слоя ResNet-34.

Такой подход позволяет модели автоматически выполнять процесс, аналогичный когнитивной деятельности эксперта-геолога. Человек мысленно сопоставляет текстуру и цвет породы (дневной свет) с характером свечения углеводородов (УФ-свет). Нейросеть, обрабатывая единый шестиканальный вход, учится извлекать сложные совместные признаки, находя нелинейные зависимости между текстурными особенностями породы и параметрами флуоресценции, которые могут быть неочевидны при раздельном анализе.

После прохождения через общую основу (backbone) ResNet-34 извлеченный 512-мерный вектор признаков подается на три независимые классификационные «головы» с функцией активации Softmax. Каждая голова решает свою задачу: классификация типа свечения, классификация характера свечения, классификация интенсивности свечения.

Совместная оптимизация с использованием суммарной функции потерь (сумма трех кросс-энтропий) позволяет каждой задаче использовать общие, универсальные признаки, извлеченные из обоих спектров. Это приводит к синергетическому эффекту, повышая точность классификации на 7–10 процентных пунктов по сравнению с обучением трех независимых сетей. Помимо прочего, в работе были применены современные подходы и технологии [18–24] для достижения максимальной эффективности модели.

Пример работы алгоритма приведен на рис. 3. На нем изображены два случайно выбранных фрагмента *a* и *б* в дневном и УФ-свете (УФ-свет приведен к бинарному формату для наглядности), а также результат определения УФ-свечения для каждого из них (Day+bbbox). В верхней части каждого фрагмента даны результаты работы алгоритма по классификации УФ свечения.

Для фрагмента *a* алгоритм полностью совпал с экспертной разметкой: правильно определены тип – «УВ», характер — «Л, П» и низкая интенсивность свечения; красный прямоугольник точно обводит узкую вертикальную зону флуоресценции, что подтверждает корректную локализацию. Фрагмент *б* демонстрирует более сложную геометрию породы: сколы, теневые участки и частичное перекрытие маски верхним слоем. Даже в этих условиях bounding-box верно выделяет активную область, интенсивность классифицируется как низкая, а характер свечения совпадает с экспертным («Л»).




Рис. 3. Пример работы алгоритма определения нефтенасыщенности для двух случайных фрагментов а и б: Day – дневное изображение фрагмента; UV – УФ-изображение фрагмента (приведенное к бинарному формату); Day+bbox – результаты выделения зоны флуоресценции

Fig. 3. Example of operation of oil saturation determination algorithm for two random fragments a and b: Day – daytime image of the fragment; UV – UV image of the fragment (converted to binary format); Day+bbox – results of fluorescence zone detection

Ошибка возникла лишь в атрибуте type: модель пометила снимок как «УВ?» вместо истинного «УВ», что типично для классов, представленных единичными образцами. В целом изображения иллюстрируют, что сеть уверенно локализует зоны свечения и надёжно предсказывает два из трёх атрибутов даже в неблагоприятных визуальных условиях.

Таким образом, алгоритм является гибридным, так как основан на гибридном конвейере, последовательно использующем несколько различных моделей машинного обучения: модифицированную U-Net для точной сегментации образцов керна и ResNet-34 для их последующей классификации. Кроме того, ResNet-34 использует мультимодальный вход, а также сочетает в себе экстрактор признаков backbone и три независимые классификационные «головы», каждая из которых специализируется на своей узкой задаче.

Разработанный алгоритм имеет большое практическое значение для автоматизации и повышения качества работы специалистов лаборатории исследования керна. Однако применение его в текущем виде затруднительно. Для решения этой проблемы следующим этапом работы является прикладная реализация полученного алгоритма.

Архитектура и реализация интеллектуальной информационной системы

Практическое применение разработанных алгоритмов требует создания надежной и масштабируемой программной платформы. Для этой цели была спроектирована и реализована ИИС на основе микросервисной архитектуры. Архитектура системы представлена на рис. 4.

Система состоит из набора слабосвязанных, независимо развертываемых сервисов. Оркестрация и бизнес-логика реализованы на ASP.NET Core, что обеспечивает высокую производительность. Задачи машинного обучения, требующие интенсивных вычислений и специализированных библиотек, вынесены в отдельные сервисы на Python.

Взаимодействие между сервисами осуществляется асинхронно через брокер сообщений Apache Kafka. Этот компонент играет ключевую роль в обеспечении отказоустойчивости и масштабируемости. Когда пользователь загружает изображение, задача на его обработку помещается в очередь Kafka. Сервисы-обработчики забирают задачи из очереди, выполняют их и публикуют результаты в другие очереди.




Рис. 4. Архитектура ИИС в нотации C4 (уровень компонентов)
 Fig. 4. IIS Architecture in C4 Notation (Component Level)

Такой подход позволяет системе справляться с пиковыми нагрузками и гарантирует, что сбой одного сервиса не приведет к остановке всей системы. Использование идемпотентных продюсеров и транзакционных коммитов обеспечивает семантику доставки сообщений *exactly-once*, предотвращая потерю или дублирование данных.

Выбранная архитектура превращает систему из статичного инструмента в динамичную и расширяемую платформу. Благодаря Kafka и четко определенным форматам сообщений в систему можно легко добавлять новые аналитические модули. Например, можно разработать новый сервис для прогнозирования пористости, который будет

подписываться на сообщения о завершении сегментации, выполнять свой анализ и публиковать результаты. Это значительно ускоряет цикл исследований и разработок новых методов цифровой петрофизики.

Система хранения данных спроектирована с учетом гетерогенности информации:

- MinIO: S3-совместимое объектное хранилище используется для больших бинарных данных – исходных и сегментированных изображений. Хранение только сегментированных областей интереса вместо полных фотографий коробок с керном позволяет сократить требуемый объем дискового пространства на 20–40 %.

- MongoDB: документо-ориентированная СУБД выбрана для хранения метаданных. Ее гибкая схема идеально подходит для геологических данных, которые могут сильно варьироваться между разными месторождениями и скважинами, избавляя от необходимости жестко структурировать данные, как в реляционных БД.
- PostgreSQL: традиционная реляционная СУБД используется для хранения информации о пользователях и их правах доступа, где важна транзакционная целостность данных.

Система также включает модуль для распознавания и валидации рукописных меток на керне. Базовая точность распознавания с помощью EasyOCR (72,4 %) значительно улучшается за счет алгоритма постобработки, который применяет логические правила и выполняет проверку на консистентность с соседними образцами.

Результаты исследования

Эффективность предложенных алгоритмов и реализованной системы была оценена на наборе реальных данных, состоящем из 108 образцов керна с макрофотографиями в дневном и УФ-свете. Датасет был разделен в соотношении 70/30 на обучающую и валидационную выборки со стратификацией по типу свечения.

Для оценки качества мультимодальной модели классификации УФ-свечения на базе ResNet-34 были рассчитаны стандартные метрики на валидационной выборке. Результаты представлены в таблице.

Таблица. Результаты валидации модели классификации УФ-свечения

Table. Validation results of the UV fluorescence classification model

Выход модели Model output	Точность Accuracy	Макро- усреднённая F-мера Macro-F1	Взвешенная F-мера Weighted-F1
Тип свечения Glow type	0,90	0,65	0,85
Интенсивность Intensity	0,80	0,63	0,79
Характер Nature	0,60	0,46	0,70

Анализ данных, приведенных в таблице, показывает высокую эффективность модели при решении наиболее важных для оценки нефтенасыщенности задач. Так, точность (Accuracy) определения типа свечения достигает 90 %, а интенсивности – 80 %. Эти показатели сопоставимы с результатами работы эксперта, но достигаются автоматически и за доли секунды. В частности, для ключевого класса «УВ» (наличие углеводородов) модель проде-

монстрировала precision=0,89 и recall=1,00, что говорит о ее способности безошибочно идентифицировать все нефтенасыщенные образцы при минимальном количестве ложных срабатываний.

Более низкая точность (60 %) для классификации характера свечения объясняется сильным дисбалансом классов в обучающей выборке, где некоторые типы характера были представлены единичными примерами. Метрика Macro-F1, которая не учитывает размер классов, наглядно отражает эту проблему (значения 0,46–0,65). В то же время метрика Weighted-F1, взвешенная по количеству образцов в каждом классе, показывает более высокие значения (0,70–0,85), подтверждая хорошую общую производительность модели.

Обсуждение и заключение

Проведенное исследование демонстрирует успешное создание и валидацию комплексного решения для автоматизированного анализа нефтенасыщенности керна. Результаты подтверждают, что интегрированный подход, сочетающий передовые методы машинного обучения и современную архитектуру программного обеспечения, способен кардинально трансформировать традиционные рабочие процессы в петрофизике.

Ключевым фактором высокой точности классификации (90 % для типа свечения) стал мультимодальный анализ, реализованный через шестиканальную архитектуру нейронной сети. Этот подход позволяет модели извлекать синергетические признаки из двух различных спектров (видимого и УФ), имитируя и формализуя сложный аналитический процесс, выполняемый экспертом-геологом.

Практическая значимость работы заключается не только в автоматизации и объективизации анализа. Созданная ИИС формирует структурированную, централизованную и легкодоступную цифровую базу данных по образцам керна. Это открывает возможности для крупномасштабной аналитики, поиска скважин-аналогов и построения более сложных геологических моделей, что было практически невозможно при традиционном хранении данных в виде разрозненных файлов и отчетов. Устранение субъективности и стандартизация оценки УФ-свечения позволяют получать более надежные и воспроизводимые данные для принятия решений при проектировании разработки месторождений.

Тем не менее исследование имеет определенные ограничения. Основным из них является невысокая точность классификации характера свечения, что напрямую связано с несбалансированностью классов в доступном наборе данных. Для решения этой проблемы направлениями будущих исследований могут стать:

- целенаправленное пополнение датасета: сбор и разметка дополнительных образцов, представляющих редкие классы характера свечения;
- применение специализированных ML-техник: исследование алгоритмов, разработанных для работы с несбалансированными данными, таких как методы взвешивания классов (cost-sensitive learning) или генерация синтетических примеров (например, SMOTE).

Кроме того, разработанная микросервисная архитектура является идеальной основой для дальнейшего расширения функциональности системы. В будущем платформа может быть дополнена новыми сервисами для интеграции и анализа других типов геологических данных, например, результатов петрофизических исследований (ГИС), данных

рентгеновской компьютерной томографии или геохимического анализа. Это позволит создать единую, комплексную платформу для всесторонней цифровой характеристики коллекторов.

В заключение представленная работа предлагает целостное решение актуальной проблемы нефтегазовой отрасли. Разработанные алгоритмы и программная платформа позволяют перейти от медленных, ручных и субъективных методов анализа керна к быстрому, автоматизированному и объективному процессу. Это не только повышает эффективность геологоразведочных работ, но и закладывает фундамент для нового поколения инструментов цифровой петрофизики, основанных на интеллектуальном анализе данных.

СПИСОК ЛИТЕРАТУРЫ

1. Особенности изучения фильтрационных характеристик ориентированного керна 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. 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.
3. Patel A.K., Snehamoy C. Computer vision-based limestone rock-type classification using probabilistic neural network // Geoscience Frontiers. – 2016. – № 7. – P. 53–60.
4. 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. Snehamoy, T. Gautam // International Journal of Coal Science & Technology. – 2020. – № 8. – P. 737–755.
5. 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. – P. 149–152.
6. Литологическая интерпретация фотографий керна 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.
7. Артамонов В.П., Каюров Н.К. Автоматизация алгоритмов предобработки и анализа фотографий керна для целей процесса макро- и литологического описания // Интеллектуальный анализ данных в нефтегазовой области: Тезисы докладов 3 научно-практической конференции. – Новосибирск, 2022. DOI: <https://libgeo.ru/library/data-science?filter=302>
8. Дзячков С.М. и др. Автоматическое определение породы по фотографиям керна современными методами машинного обучения // Вестник Тюменского государственного университета. Серия: Физико-математическое моделирование. Нефть, газ, энергетика. – 2021. – Т. 7. – № 4 (28). – С. 181–198.
9. 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.
10. Хасанов И.И. Анализ цветности пород по цифровым изображениям керна // Геология нефти и газа. – 2014. – № 5. – С. 33–39.
11. 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.
12. US Patent № US8416413B2, 09.04.2013. Products and methods for identifying rock samples.
13. US Patent № US2017286802, 2017. Automated core description.
14. Изучение и анализ современных подходов к построению цифровых моделей керна 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.
15. Модификация архитектуры сети U-Net для задач классификации и сегментации образцов пород / А.И. Кочегуров, В.И. Денисов, Н.Е. Семенченко, Е.А. Андренкова // Системы анализа и обработки данных. – 2025. – № 2. – С. 33–52.
16. Denisov V.I., Kochegurov A.I., Semenchenko N.E. Modification of U-Net Network Architecture for Core Samples Analysis Automation // International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM 2025): Proceedings. – 2025. – P. 863–868. DOI: 10.1109/ICIEAM65163.2025.11028233
17. ResNet (34, 50, 101): «остаточные» CNN для классификации изображений // ResNet. URL: <https://neurohive.io/ru/vidy-nejrosetej/resnet-34-50-101/> (дата обращения: 20.06.2025).
18. Введение в TensorFlow // TensorFlow. URL: <https://www.tensorflow.org/learn?hl=ru> (дата обращения: 02.05.2025).
19. Keras. Get Started // Keras. URL: <https://keras.io/> (дата обращения: 02.05.2025).
20. Pillow (PIL Fork) 10.4.0 documentation // Pillow. – 2024. URL: <https://pillow.readthedocs.io/en/stable/> (дата обращения: 22.05.2025).

21. NumPy 1.26.0 released // NumPy. – 2024. URL: <https://numpy.org/> (дата обращения: 02.05.2025).
22. Scikit-Learn. Getting Started // Scikit-Learn. Machine Learning in Python. URL: https://scikit-learn.org/stable/getting_started.html (дата обращения: 02.06.2025).
23. OpenCV. Modules // Open-Source Computer Vision. URL: <https://docs.opencv.org/4.x/> (дата обращения: 09.04.2025).
24. Dropout – метод борьбы с переобучением нейронной сети // Введение в нейронные сети. – 2024. URL: https://proproprogs.ru/neural_network/dropout-metod-borby-s-pereobucheniem-neyronnoy-seti (дата обращения: 11.03.2025).

Информация об авторах

Александр Иванович Кочегуров, 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

Владислав Игоревич Денисов, аспирант отделения информационных технологий Инженерной школы информационных технологий и робототехники Национального исследовательского Томского политехнического университета, Россия, 634050, г. Томск, пр. Ленина, 30. lor.net.dv@gmail.com

Никита Евгеньевич Семенченко, студент отделения информационных технологий Инженерной школы информационных технологий и робототехники Национального исследовательского Томского политехнического университета, Россия, 634050, г. Томск, пр. Ленина, 30. nes13@tpu.ru

Елизавета Александровна Андренкова, студент отделения математики и математической физики Инженерной школы ядерных технологий Национального исследовательского Томского политехнического университета, Россия, 634050, г. Томск, пр. Ленина, 30. eaz28@tpu.ru

Поступила в редакцию: 19.08.2025

Поступила после рецензирования: 16.09.2025

Принята к публикации: 17.09.2025

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. Kochegurov A.I., Denisov V.I., Zadorozhnykh E.A. Analysis of the application of machine learning methods in problems of rock classification on core samples. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*, 2024, vol. 335, no. 9, pp. 148–159. (In Russ.)
3. Patel A.K., Snehomoy C. Computer vision-based limestone rock-type classification using probabilistic neural network. *Geoscience Frontiers*, 2016, no. 7, pp. 53–60.
4. Gorai A.G., Raval S., Patel A.K., Snehomoy 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.
5. 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. pp. 149–152.
6. Ivchenko A.V., Baraboshkin E.E., Ismailova L.S. 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.)
7. 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 3rd scientific and practical conference. Intelligent data analysis in the oil and gas field*. Novosibirsk, 2022. (In Russ.) DOI: <https://libgeo.ru/library/data-science?filter=302>
8. 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.)
9. Postnikov A.V., Postnikova O.V., Olenova K.Yu., Khasanov I.I. New methodological aspects of lithological research of rocks of the Bazhenov formation. *Oil Industry*, 2015, no. 10, pp. 23–27. (In Russ.)
10. Khasanov I.I. Analysis of rock color using digital core images. *Geology of Oil and Gas*, 2014, no. 5, pp. 33–39. (In Russ.)
11. 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, pp. 1–5.
12. Ellington W.E., Moore J.C., Smith M.A. *Products and methods for identifying rock samples*. US Patent no. US8416413B2, 2013.
13. Mezghani M.M., Shammari S.H., Anifowose F.A. *Automated core description*. US Patent no. US2017286802, 2017.
14. 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. (In Russ.)
15. Kochegurov A.I., Denisov V.I., Semenchenko N.E., Andrenkova E.A., modification of the U-Net architecture for classifying and segmentifying rock samples. *Systems of data analysis and processing*, 2025, no. 2, pp. 33–52. (In Russ.)
16. Denisov V.I., Kochegurov A.I., Semenchenko N.E. Modification of U-Net Network Architecture for Core Samples Analysis Automation. *International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM 2025). Proceedings*, 2025, pp. 863–868. DOI: 10.1109/ICIEAM65163.2025.11028233
17. ResNet (34, 50, 101): "Residual" CNNs for image classification. Available at: <https://neurohive.io/ru/vidy-nejrosetej/resnet-34-50-101/> (accessed 20 June 2025).
18. *Introduction in TensorFlow*. (In Russ.) Available at: <https://www.tensorflow.org/learn?hl=ru> (accessed 02 May 2025).

19. *Keras. Get Started*. Available at: <https://keras.io/> (accessed 02 May 2025).
20. *Pillow (PIL Fork) 10.1.0 documentation*. Available at: <https://pillow.readthedocs.io/en/stable/> (accessed 22 May 2025).
21. *NumPy 1.26.0 released. NumPy*. Available at: <https://numpy.org/> (accessed 02 May 2025).
22. *Scikit-Learn. Getting Started. Scikit-Learn. Machine Learning in Python*. Available at: https://scikit-learn.org/stable/getting_started.html (accessed 02 June 2025).
23. *OpenCV. Modules. Open-Source Computer Vision*. Available at: <https://docs.opencv.org/4.x/> (accessed 09 April 2025).
24. *Dropout – a method for combating neural network overtraining. Introduction to neural networks*. Available at: https://propoprops.ru/neural_network/dropout-metod-borby-s-pereobucheniem-neyronnoy-seti (accessed 11 March 2025).

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, <https://orcid.org/0000-0002-9008-3529>

Vladislav I. Denisov, Postgraduate Student, National Research Tomsk Polytechnic University, 30, Lenin avenue, Tomsk, 634050, Russian Federation. l0rnet.dv@gmail.com

Nikita E. Semenchenko, Student, National Research Tomsk Polytechnic University, 30, Lenin avenue, Tomsk, 634050, Russian Federation. nes13@tpu.ru

Elizaveta A. Andrenkova, Student, National Research Tomsk Polytechnic University, 30, Lenin avenue, Tomsk, 634050, Russian Federation. eaz28@tpu.ru

Received: 19.08.2025

Revised: 16.09.2025

Accepted: 17.09.2025