

Федеральное государственное автономное образовательное учреждение  
высшего образования  
**«НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ  
ТОМСКИЙ ПОЛИТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ»**

---

*На правах рукописи*

**Денисов Владислав Игоревич**

**АНАЛИЗ ИЗОБРАЖЕНИЙ КЕРНА В ВИДИМОМ И  
УЛЬТРАФИОЛЕТОВОМ ДИАПАЗОНАХ ДЛЯ ОЦЕНКИ  
НЕФТЕНАСЫЩЕННОСТИ ПОРОД И ХРАНЕНИЯ ЦИФРОВЫХ ДАННЫХ  
НА ОСНОВЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ**

Специальность 2.3.1 – Системный анализ, управление и обработка информации,  
статистика

Диссертация на соискание ученой степени  
кандидата технических наук

**Научный руководитель:**  
Кандидат технических наук, доцент  
Кочегуров Александр Иванович

## Оглавление

ВВЕДЕНИЕ.....	5
Глава 1. Анализ применения методов машинного обучения в задачах исследования пород на изображениях керна .....	14
1.1. Понятие керна и его исследования для прогноза геологического разреза.....	14
1.1.1. Процесс отбора и подготовки керна к исследованию.....	14
1.1.2. Макроскопический анализ керна .....	18
1.2. Применение методов компьютерного зрения для анализа пород на изображениях керна .....	25
1.2.1. Анализ цветности пород по изображениям керна.....	25
1.2.2. Анализ пород с помощью нейросетевых технологий.....	28
1.3. Выводы по первой главе.....	35
Глава 2. Разработка гибридной архитектуры нейронной сети для семантической сегментации образцов пород .....	37
2.1. Поиск и обоснование выбора архитектуры сети .....	38
2.1.1. Методология эксперимента и подготовка данных .....	38
2.1.2. Сравнительный анализ архитектур .....	40
2.1.3. Метрики качества сегментации.....	44
2.1.4. Результаты эксперимента.....	46
2.1.5. Обоснование выбора U-Net для дальнейшего исследования.....	48
2.2. Влияние раздробленности керна на результаты сегментации .....	49
2.2.1. Анализ U-Net архитектуры .....	51
2.2.2. Анализ U-Net++ архитектуры.....	54
2.2.3. Анализ Yolo .....	57

2.2.4. Выводы о влиянии раздробленности .....	60
2.3. Создание гибридной архитектуры для повышения эффективности сегментации на образцах керна .....	61
2.3.1. Уменьшение числа параметров и ускорение вычислений.....	61
2.3.2. Добавление промежуточных связей между слоями.....	62
2.3.3. Снижение риска «забывания» ранних признаков и улучшение сходимости.....	63
2.3.4. Увеличение эффективности работы на сильно раздробленных образцах керна.....	64
2.3.5. Разработка алгоритма «онлайн» аугментации.....	65
2.3.6. Настройка гиперпараметров и оценка качества работы гибридной архитектуры .....	67
2.4. Выводы по второй главе.....	72
Глава 3. Разработка алгоритма оценки нефтенасыщенности образцов керна на основе УФ-свечения.....	75
3.1. Связь УФ-свечения керна с нефтенасыщенностью.....	75
3.2. Формализация признаков УФ-свечения .....	77
3.3. Формирование датасета.....	78
3.4. Модель многозадачной классификации УФ-свечения .....	82
3.5. Проведение вычислительного эксперимента и оценка эффективности модели.....	86
3.6. Научная новизна и отличие от существующих подходов .....	89
3.7. Выводы по третьей главе .....	90
Глава 4. Программная реализация интеллектуальной информационной системы	92
4.1. Постановка задачи, решаемой ИИС.....	92

4.2. Концепция создания информационной системы .....	94
4.3. Архитектурные решения .....	97
4.4. Оценка эффективности хранения сегментированных изображений керна .....	101
4.5. Алгоритм обработки результатов OCR .....	104
4.6. Выводы по четвертой главе .....	108
ЗАКЛЮЧЕНИЕ .....	111
СПИСОК СОКРАЩЕНИЙ И ОПРЕДЕЛЕНИЙ .....	113
СПИСОК ИСПОЛЬЗУЕМОЙ ЛИТЕРАТУРЫ .....	116
Приложение А Псевдокод алгоритма онлайн аугментации .....	130
Приложение Б Постобработка результатов OCR распознавания .....	131
Приложение В Акты внедрения результатов диссертационной работы.....	132

## ВВЕДЕНИЕ

**Актуальность темы исследования.** Практическая геология нефтегазовой отрасли концентрируется на разведке полезных ископаемых и количественной оценке их запасов [1-3]. Знание строения и свойств пород позволяет локализовать нефтегазоносные горизонты, спланировать бурение и минимизировать риски разработки [4-6]. Ключевым источником достоверной информации о пласте служит керн – монолитный цилиндрический образец горной породы, извлекаемый колонковым бурением. Главная цель анализа керна – получение данных о недрах [7]. Изображения пород на фотографиях керна представляют собой один из основных источников информации для проведения литолого-фациального анализа на ранних этапах разработки. Проведенные исследования дают возможность говорить о строении геологического разреза, составе пород и насыщении пластов, а также о положении стратиграфических границ, реперных слоев и нахождении коллекторов [8-10]. Таким образом, анализ керна имеет решающее значение для определения свойств пласта и создания гидродинамических моделей месторождений, что является основой для планирования разработки недр.

Количество новых изображений керна, которые требуется анализировать, с каждым годом только растет. Вследствие этого увеличивается штат высококвалифицированных специалистов-геологов, а ввиду субъективности и человеческого фактора неизбежно растёт количество некорректно проанализированных образцов. При этом в процессе составления проекта разработки месторождения необходимо возвращаться и к образцам, полученным ранее, так как по ним можно подбирать аналоги и строить зависимости. Это требует выделения сотен терабайт дискового пространства для хранения фотографий пород в высоком разрешении, а также приводит к значительному затруднению при поиске конкретного образца или подбору аналогов по заданным параметрам. Поэтому в настоящее время применение современных технологий, таких как машинное обучение, для анализа изображений керна является распространенным методом

исследования. В этом плане значительное место занимают нейронные сети, результаты применения которых представлены большим количеством работ, среди которых следует выделить работы А. Пателя, Е. Барабошкина, В. Артамонова и С. Дьячкова [11-16].

Однако в большинстве опубликованных работ авторы никак не используют изображения образцов керн в ультрафиолетовом (УФ) диапазоне, хотя ультрафиолетовое свечение позволяет выделить на изображениях нефтенасыщенные участки; выделение таких участков позволит в дальнейшем произвести расчеты нефтенасыщенности и сделать вывод о наличии флюида на том или ином интервале [17].

Первым шагом к решению данной задачи является введение автоматической сегментации изображений образцов керн. Сегментация позволяет сохранить неровности и форму керн, которые в традиционных методах просто обрезаются, а значит, улучшить качество последующего анализа; еще одним преимуществом сегментации является более эффективный анализ породы относительно тех случаев, когда на вход подают всю фотографию керн – вместе с шумом (коробка, заполнитель пустого пространства секций), который может занимать до 27% изображения. Кроме того, этот подход эффективно работает даже с сильно раздробленными фрагментами, где ручная обрезка особенно трудоёмка.

Помимо этого, сегментация служит основой для выявления нефтенасыщенных зон. Однако для решения данной задачи необходимо сегментировать не только изображения керн в видимом диапазоне, но также и в ультрафиолетовом. Так, на первом этапе на изображениях в видимом диапазоне необходимо отделить породу от фона и других объектов – по сути, решить задачу бинарной классификации («пиксель порода» и «пиксель не порода»). А уже затем провести сегментацию изображений в ультрафиолете. Для этого прежде всего необходимо иметь сбалансированную архитектуру нейросети, обеспечивающую надежную сегментацию образцов керн.

Таким образом, несмотря на активное применение методов машинного обучения для исследования керна, в сегодняшней нефтегазовой отрасли недостаточно инструментов, которые позволили бы:

- увеличить количество анализируемых изображений образцов без снижения качества анализа;
- снизить влияние человеческого фактора и повысить воспроизводимость и точность оценки признаков нефтенасыщенности в том числе сделать вывод о наличии флюида на том или ином интервале;
- сократить место, занимаемое данными с изображениями образцов керна, а также повысить эффективность поиска по этим данным.

**Целью диссертационной работы** является разработка и исследование алгоритмов оценки нефтенасыщенности пород и хранения цифровых данных на основе нейросетевого анализа изображений керна в видимом и ультрафиолетовом диапазонах.

В рамках поставленной цели предполагается решить следующие задачи:

- провести анализ существующих алгоритмов исследования изображений керна, выделить их основные преимущества и недостатки;
- построить гибридную архитектуру нейронной сети для повышения точности сегментации изображений керна;
- разработать алгоритм выделения зон ультрафиолетового свечения и их последующую классификацию по признакам: тип, характер и интенсивность;
- осуществить программную реализацию алгоритмов классификации и хранения изображений керна в видимом и ультрафиолетовом диапазонах.

**Методы исследования.** Для решения поставленных задач в настоящей работе использованы методы цифровой обработки изображений, технология компьютерного зрения, методы машинного обучения, системного анализа и математической статистики. Численные расчеты проводились путем вычислительного эксперимента на построенных моделях нейронных сетей, программирование осуществлялось в среде Python и C#. Выбор языка для задач,

связанных с машинным обучением, обусловлен необходимостью использования специализированных библиотек глубокого обучения.

**Объект исследования.** Цифровые изображения образцов керн в видимом и ультрафиолетовом диапазонах.

**Предмет исследования.** Методы и алгоритмы машинного и глубокого обучения для семантической сегментации изображений керн, выделения и классификации УФ-свечения, а также программные средства хранения и обработки сегментированных цифровых изображений керн.

**Научная новизна:**

1. На основе анализа применения нейронных сетей для исследования керн и путем модификации архитектуры U-Net предложена и реализована гибридная архитектура этой сети, позволяющая сегментировать изображения раздробленных образцов керн посредством добавления промежуточных связей между слоями декодера, введения остаточных блоков, замены свертки на глубинно-разделяемую и внедрения блоков внимания.
2. Разработан гибридный нейросетевой алгоритм выделения признаков нефтенасыщенности пород, основанный на совместном анализе сегментированных изображений керн в видимом и ультрафиолетовом диапазонах.
3. Разработана и программно реализована интеллектуальная информационная система для хранения цифровых изображений керн, сегментированных с помощью предложенной гибридной нейронной сети.

**Достоверность полученных результатов.** Степень обоснованности результатов, изложенных в диссертации, обеспечивается корректностью постановки задачи и проведенными вычислениями, сопоставительным анализом предложенных подходов и алгоритмов. Подтверждается тестированием и исследованием алгоритмов на модельных и экспериментально полученных

изображениях, согласованностью полученных результатов с представленными в научной литературе.

**Практическая значимость работы.** На основе разработанных алгоритмов и программных средств построена интеллектуальная информационная система с микросервисной архитектурой, что обусловлено требованиями к независимой масштабируемости компонентов и разнообразием вычислительных задач, некоторые из которых требуют графического процессора с высокой производительностью. Информационная система представляет собой комплекс слабосвязанных модулей, где бизнес-логика отделена от ресурсоемких операций машинного обучения и обеспечивает выполнение следующих функций:

- сегментация изображений керна в видимом и ультрафиолетовом (УФ) диапазонах для отделения породы от фона;
- распознавание рукописных меток на изображениях (глубина, номер образца);
- выполнение расчетов по распознанным рукописным меткам для определения глубин залегания образцов;
- загрузка и хранение метаинформации по керну – месторождение, пласт, скважина;
- поиск по метаинформации; структурированное представление загруженных образцов для быстрой ориентации по базе керна;
- классификация УФ-свечения по трем признакам: тип, интенсивность, характер;
- оптимизация хранения данных путем сохранения только сегментированных областей изображений.

**Внедрение результатов работы.** Результаты работы внедрены в научно-производственную деятельность ООО НАЦ «Недра» (г. Томск), в учебный процесс Томского политехнического университета для студентов направления 01.03.02 «Прикладная математика и информатика» Инженерной школы ядерных технологий.

**Основные положения, выносимые на защиту:**

1. Гибридная архитектура на основе сети U-Net позволяет увеличить точность сегментации на 8%, а также сегментировать тонкие, контрастные или сложно различимые структуры ядра и стабилизировать процесс обучения нейросети.
2. Гибридный нейросетевой алгоритм для определения нефтенасыщенности пород на основе анализа изображений ядра в видимом и ультрафиолетовом диапазонах обеспечивает точность оценки ключевых параметров нефтенасыщенности (типа, интенсивности свечения ядра и характера насыщения породы) в среднем до 80%.
3. Программно реализованная интеллектуальная информационная система хранения сегментированных с помощью гибридной нейронной сети изображений ядра позволяет достичь сокращения требуемого объема памяти цифровых ядерохранилищ на 20–30%.

**Апробация.** Основные результаты данной работы докладывались, обсуждались и получили одобрение специалистов на следующих конференциях: Региональная научно-техническая конференция ПАО «НК «Роснефть», Томск, 2023 (с двумя докладами); Всероссийская научно-техническая конференция ПАО «НК «Роснефть», Тюмень, 2023 (с двумя докладами); XX Международная научно-практическая конференция студентов, аспирантов и молодых ученых, г. Томск, 2024 г.; International Conference on Industrial Engineering, Applications and Manufacturing, ICIEAM. Сочи, 2024; XXI Международная научно-практическая конференция студентов, аспирантов и молодых ученых, г. Томск, 2025 г. (с двумя докладами); International Conference on Industrial Engineering, Applications and Manufacturing, ICIEAM. Сочи, 2025; научный семинар инженерной школы информационных технологий и робототехники Томского политехнического университета, Томск, 2026.

**Публикации.** Основные научные и практические результаты диссертационного исследования опубликованы в 9 печатных работах: 3 статьи – в ведущих рецензируемых научных журналах и изданиях, рекомендованных ВАК

РФ, из них 2 публикации проиндексированы в базах научного цитирования Scopus и Web of Science; 5 докладов – в материалах и трудах международных научных конференций, из них 2 проиндексированы в Scopus; 1 статья – в журнале, входящем в РИНЦ.

**Структура и объем диссертации.** Диссертационная работа состоит из введения, четырех глав, заключения, списка литературы из 112 наименований. Работа содержит 134 страницы основного текста, включает 27 рисунков, 15 таблиц.

*Во введении* обоснована актуальность темы исследования, сформулированы цель и задачи работы, определена научная новизна, а также отражены практическая значимость и положения, выносимые на защиту.

*В первой главе* «Анализ применения методов машинного обучения в задачах исследования пород на изображениях керна» проведен теоретико-методологический анализ, обосновывающий роль керновых исследований в геолого-технических мероприятиях и выявляющий ключевые проблемы автоматизации анализа кернового материала. Критический анализ существующих методов обработки изображений керна выявил ограничения ручных подходов (трудоемкость, субъективность), полуавтоматических систем (зависимость от цветовых характеристик, человеческий фактор) и современных ML-решений (неравномерность выборок, игнорирование УФ-диапазона, фрагментарность классификации). На основе выявленных проблем (отсутствие автоматизированной сегментации, недоучет структурных особенностей, отсутствие комплексного анализа снимков в видимом и УФ диапазонах) сформулирована задача разработки модифицированной архитектуры нейронной сети для точной бинарной сегментации образцов и последующей оценки нефтенасыщенности. Ключевым научным направлением определено создание алгоритма, сохраняющего естественные контуры керна (включая раздробленные фрагменты) и интегрирующего данные мультиспектральной съемки.

*Вторая глава* «Разработка гибридной архитектуры нейронной сети для семантической сегментации образцов пород» посвящена разработке и сравнительному анализу архитектур нейронных сетей для семантической сегментации макрофотографий образцов керна. На основе сформированного и аугментированного экспертного датасета проведено детальное сравнение пяти моделей (U-Net, U-Net++, SegNet, YOLOv8-seg, YOLOv11-seg) по метрикам качества (Dice, IoU, Precision, Recall) и вычислительной эффективности. Классическая U-Net оказалась наиболее сбалансирована по совокупности показателей: точности (Dice=0,910), скорости инференса (0,15 с) и ресурсопотребления (4 ГБ). Исследовано влияние степени раздробленности образцов на качество сегментации, которое выявило необходимость адаптации архитектуры для сегментации фрагментированных образцов керна. Предложена и протестирована гибридная архитектура, повысившая точность сегментации на 8% относительно базовой U-Net и сократившая время инференса на 33%.

*В третьей главе* «Разработка алгоритма оценки нефтенасыщенности образцов керна на основе УФ-свечения» выполнена разработка и экспериментальная проверка алгоритма оценки нефтенасыщенности образцов керна на основе разработанной гибридной сети. Представлен автоматизированный конвейер обработки макрофотографий (видимый/УФ диапазоны), позволивший значительно сократить время подготовки датасета. Представлена шестиканальная ResNet-модель, достигшая точности в среднем 80% в определении ключевых параметров флуоресценции (тип, характер и интенсивность).

*Четвертая глава* «Программная реализация интеллектуальной информационной системы» представляет разработку интеллектуальной информационной системы (ИИС) для автоматизации обработки, анализа и хранения образцов керна. Система построена на микросервисной архитектуре с использованием ASP.NET Core (оркестрация), Python (ML-сервисы), Kafka (асинхронная очередь) и специализированных хранилищ: MinIO для изображений, MongoDB для метаданных. Ключевые функции включают автоматическую

сегментацию образцов (на основе разработанной во второй главе гибридной сети), классификацию нефтенасыщенности по УФ-снимкам (на основе разработанного в третьей главе алгоритма), OCR-распознавание меток с алгоритмом постобработки и формирование виртуальных керновых колонок. Архитектура сокращает объем хранимых данных на 20-30% за счет сегментации, а также повышает эффективность обработки информации за счет интеграции хранения изображений, метаданных, результатов сегментации, распознавания и классификации в единой программной среде.

## **Глава 1. Анализ применения методов машинного обучения в задачах исследования пород на изображениях керна**

В данной главе сначала описаны теоретические основы исследования керна как одного из важнейших источников информации о строении недр, после чего рассмотрено применение методов компьютерного зрения в задачах анализа изображений пород.

### **1.1. Понятие керна и его исследования для прогноза геологического разреза**

Данные, полученные при лабораторном изучении керна, служат фундаментом для всего комплекса геолого-технических мероприятий, начиная от оценки запасов углеводородов и заканчивая проектированием и мониторингом разработки месторождения. Эти данные позволяют судить о геологическом строении недр, условиях осадконакопления, вещественном составе горных пород и, что наиболее важно, о наличии и характере распределения в них углеводородов [8-10].

#### **1.1.1. Процесс отбора и подготовки керна к исследованию**

Керн, представляющий собой цилиндрический образец горной породы, извлеченный из продуктивного пласта в процессе бурения скважины, является единственным прямым и наиболее достоверным источником информации о строении и свойствах коллектора. Пример образца керна, подготовленного к анализу, приведен на рисунке 1.1.



Рисунок 1.1 – Пример образца керна

Каждая порода-коллектор несет в себе отпечаток долгой геологической истории. Первичные свойства пласта закладываются в момент осадконакопления и определяются физико-географическими условиями среды: была ли это речная дельта, мелководный морской шельф или глубоководный конус выноса. Впоследствии, в процессе погружения на глубину, порода претерпевает вторичные, или постседиментационные, изменения, такие как механическое уплотнение под весом вышележащих осадков, цементация порового пространства новообразованными минералами (например, кальцитом, кварцем, глинистыми минералами), частичное или полное растворение неустойчивых зерен с образованием вторичной пористости, а также процессы перекристаллизации [18-23]. Пример образцов керна, на которых отчетливо видны вкрапления и следы осадконакопления, приведен на рисунке 1.2.



Рисунок 1.2 – Разрезанные образцы керна со следами осадконакопления

Эти процессы могут как улучшить коллекторские свойства (например, за счет образования каверн выщелачивания в известняках), так и значительно ухудшить их (например, при заполнении пор аутигенным каолинитом или хлоритом) [23]. КERN является единственным источником, позволяющим напрямую наблюдать и расшифровывать эту сложную историю, связывая воедино среду осадконакопления и последующие диагенетические преобразования для построения прогностической геологической модели [24].

Отбор керна осуществляется с помощью специального снаряда – керноприемника, который спускается в скважину на бурильных трубах. Наиболее распространены два типа [8, 10]:

Стандартный отбор: в этом методе керн поступает во внутренний керновый ствол по мере углубления долота. Главным недостатком является возможность промывки и механического повреждения керна буровым раствором, особенно в хрупких и трещиноватых породах.

Боковой отбор: предполагает отбор керна из стенки уже пробуренной скважины с помощью специальных грунтоносов. Позволяет точно отобрать образцы в интересующих интервалах, но объем образца мал, а степень механического повреждения, как правило, выше.

Качество отобранного керна напрямую определяется тем, насколько правильно выбраны технология бурения, тип долота и параметры бурового раствора, позволяющие минимизировать его фильтрацию в породу и механическое воздействие на столбик породы [10].

После извлечения на поверхность керн проходит ряд обязательных операций. Понимание этих операций в рамках настоящей работы принципиально, поскольку они напрямую влияют на данные, которые впоследствии будут получены из макроизображений керна [9]:

1. Экстракция и укладка: керн аккуратно извлекается из керноприемника и укладывается в керновые ящики, как показано на рисунке 1.3.




Рисунок 1.3 – Пример образца керна, уложенного в ящик

2. Очистка и маркировка: поверхность керна очищается от шлама и бурового раствора. На ящики наносятся метки номера керна, диапазона глубин отбора, положения текущей части относительно всего столбика (например, «продолжение керна»); также для каждого фрагмента на коробку наносятся метки верхней и нижней границы интервала отбора, как показано на рисунке 1.4. Всё это обеспечивает корректную привязку образцов к разрезу скважины.



Рисунок 1.4 – Пример маркировки ориентации на ящике керна

3. Первичное документирование: на данном этапе выполняется фотографирование в видимом и УФ диапазонах, как показано на рисунке 1.5, а также оперативное описание торцевых срезов (сколов) для экспресс-оценки литологии и насыщенности.



Рисунок 1.5 – Пример образца керна в коробке в УФ-диапазоне

4. Консервация и транспортировка: для сохранения нативной насыщенности флюидами керн может консервироваться: покрываться парафином, замораживаться или помещаться в герметичные контейнеры в инертной среде.

### 1.1.2. Макроскопический анализ керна

В комплексном керновом анализе важную роль играет макроскопическое исследование, заключающееся в визуальном описании и анализе изображений керна в видимом и УФ диапазонах. Этот этап, часто воспринимаемый как рутинный и субъективный, на самом деле является критически важным первым шагом, который задает направление для всех последующих, более сложных и дорогостоящих лабораторных исследований [9]. Современные технологии цифровой фотографии и обработки изображений позволяют преобразовать субъективное описание в количественные и воспроизводимые данные, что значительно повышает ценность керновой информации.

Макроскопический анализ является отправной точкой для всего комплекса лабораторных исследований. Он позволяет получить первичную, но фундаментально важную информацию, на основе которой планируются все дальнейшие, более узкоспециализированные и дорогостоящие анализы. По результатам визуального осмотра и анализа макроизображений производится разметка и отбор образцов для [7-10]:

- стандартных и специальных петрофизических исследований, которые нужны для определения фильтрационно-емкостных свойств (пористости, проницаемости), смачиваемости, капиллярных свойств и относительных фазовых проницаемостей;
- литолого-седиментологических исследований, направленных на детальное изучение вещественного состава, структуры порового пространства (изготовление шлифов), реконструкцию условий осадконакопления;
- геомеханических исследований, которые требуются для определения прочностных и упругих свойств пород (модуль Юнга, коэффициент Пуассона), необходимых для проектирования гидроразрыва пласта и обеспечения устойчивости ствола скважины;

- геохимических исследований, в ходе которых выполняется анализ органического вещества, состава нефти, определение степени зрелости материнских пород.

Таким образом, макроскопический анализ позволяет целенаправленно и экономически эффективно провести углубленное изучение керна, сфокусировав усилия на наиболее репрезентативных и информативных интервалах.

Литолого-фациальное описание является ключевой задачей макроскопического анализа, требующей привлечения высококвалифицированных специалистов-геологов. Литолого-фациальное описание состоит из [25-34]:

- выделения коллекторов и флюидоупоров;  
Этот анализ направлен на четкое разграничение интервалов, способных вмещать и фильтровать флюиды, от непроницаемых слоев и выражается в определении типов пород, на основании которых уже можно сделать заключение о расположении коллекторов.
- выявления и документирования неоднородностей;  
Описание трещин (естественных и техногенных), каверн, стилолитовых швов, прослоев глин, которые контролируют пути фильтрации в пласте. Данный вид анализа позволяет восстановить условия осадконакопления, однако требует большого количества работы специалистов-геологов.
- оценки коллекторских свойств;  
Анализ состоит из качественной оценки пористости и проницаемости на основе визуальных признаков. Хотя эти данные и являются важными, но визуально их оценить возможно лишь с очень большой погрешностью.
- выявления и картирования насыщенности;  
Заключается в определении характера насыщающего флюида и его распределения по пласту. Выявление нефтенасыщенности позволяет получить очень важные данные о керне, на основе которых далее будет составляться проект разработки.

- создания основы для интерпретации геофизических исследований скважины (ГИС);
- привязка литологических разностей и неоднородностей к кривым каротажа.

При макроскопическом анализе фотографирование и описание керна в видимом спектре является базовым методом. Ключевые параметры для описания, приведенные ниже, напрямую связаны с геологическими процессами [9, 10, 35-38]:

#### 1. Цвет

Является индикатором не только литологии, но и геохимической обстановки. Например, красные и бурые оттенки в континентальных отложениях часто свидетельствуют об окислительных условиях, тогда как темно-серые и черные цвета в морских осадках указывают на бескислородную среду и высокое содержание органического вещества.

#### 2. Гранулометрический состав

Размер, окатанность и сортировка зерен говорят об условиях образования и длительности переноса.

#### 3. Тектурные особенности

Косая слоистость указывает на направленное течение (река, приливно-отливные течения). Градационная слоистость характерна для турбидитных потоков в глубоководных условиях. Горизонтальная и волнистая слоистость формируется в более спокойных обстановках. Наличие биотурбаций свидетельствует о присутствии донной фауны и, как правило, о низких темпах осадконакопления.

#### 4. Состав

Приблизительная оценка минерального состава (например, наличие пирита, глауконита, карбонатных прожилок, примеси глинистого материала).

#### 5. Характер пористости

Визуальная оценка типа и размера пор (межзерновая, каверновая, трещинная). Например, в карбонатных породах часто встречается пористость

выщелачивания, когда подземные воды растворяют менее стойкие компоненты, создавая крупные каверны.

#### 6. Наличие и характеристика трещин

Описание трещин (открытые/закрытые, минерализованные, с зонами выщелачивания), их ориентировка, плотность и распределение.

Еще одним ключевым параметром, не упомянутым выше, является УФ-свечение. Анализ в ультрафиолетовом диапазоне основан на свойстве многих компонентов нефти флуоресцировать под воздействием УФ-излучения. Интенсивность и цвет свечения (от желтого и зеленого до голубого и белого) зависят от химического состава нефти: плотности, содержания смолисто-асфальтеновых компонентов, степени окисления и зрелости [9].

УФ-съемка позволяет мгновенно визуализировать распределение нефти по керну, что невозможно при описании в видимом диапазоне, особенно для легких нефтей. Нефтенасыщенные участки ярко светятся, как показано на рисунках 1.6, 1.7, в то время как водоносные зоны остаются темными.




Рисунок 1.6 – Пример свечения нефтенасыщенного участка в УФ-диапазоне




Рисунок 1.7 – Пример свечения линзы в УФ-диапазоне

Цвет свечения является грубым индикатором плотности углеводородов. Обычно тяжелые, смолистые нефти светятся желто-оранжевым или коричневым светом, легкие – голубовато-белым [9].

УФ-фотография выявляет тонкие прослои, линзы и зоны с различной насыщенностью, которые могут быть не видны невооруженным глазом. Характер свечения (сплошное, пятнистое) может указывать на особенности смачиваемости породы. Это критически важно для понимания гидродинамики пласта и проектирования систем заводнения.

Контроль качества отбора керн позволяет оценить, насколько керн был промыт буровым раствором. Резкая граница свечения может указывать на зону инвазии фильтрата бурового раствора и, следовательно, на ненадежность данных о насыщенности в этой части образца [39-41].

Совмещение изображений в видимом и УФ диапазонах предоставляет мощный инструмент для корреляции литологических особенностей с характером насыщения, позволяя выделять интервалы с наилучшими фильтрационно-емкостными свойствами и прогнозировать их пространственное распространение.

Конечная цель любого кернового исследования - снижение неопределенностей при построении статической и динамической моделей месторождения. Данные макроописания служат основой для построения трехмерной фациальной модели месторождения, которая выступает геологическим каркасом для распределения петрофизических свойств. Без такого каркаса распределение пористости и проницаемости превратилось бы в только статистическую интерполяцию, не учитывающую геологическую логику [42, 43]. Детальное описание керн также позволяет выделять ключевые стратиграфические поверхности - границы секвенций, поверхности максимального затопления, которые лежат в основе построения секвенс-стратиграфической модели и корреляции пластов по всей площади месторождения. Количественные параметры трещин, полученные по керну, остаются одними из ключевых входных данных при построении дискретных моделей трещиноватых коллекторов [44-48].

Непрерывные количественные данные, получаемые при описании керна, используются и для калибровки кривых ГИС (например, резистивиметрии), а также для построения зависимостей «кern-каротаж». Это повышает достоверность интерпретации ГИС в скважинах, с которых не отбирался kern [49-52].

Данные анализа макрофотографий керна активно применяются и при обосновании проектных решений по разработке. Точное понимание распределения проницаемых и нефтенасыщенных пропластков дает возможность более обоснованно выбирать интервалы для перфорации, избегая обводняющихся зон и непродуктивных слоев [53, 54]. Модель, построенная с учетом тонкой слоистости, выявленной по керну, позволяет точнее прогнозировать фронт вытеснения и время прорыва воды, особенно при реализации проектов заводнения [55].

При этом затраты на отбор керна и его анализ составляют лишь доли процента от общих капитальных затрат на проект, тогда как их влияние на экономику проекта носит системный характер и во много раз превышает понесенные расходы [56-57]. За счет качественного и объективного анализа макроизображений керна можно получить следующие результаты [58-63]:

- снижение геологических рисков;

Корректная интерпретация макроизображений помогает избежать ошибок при оценке объема геологических запасов. Завышение оценки вследствие невыявленной глинистости или низкой эффективной пористости может привести к инвестициям в нерентабельную разработку. Занижение оценки, наоборот, ведет к недополучению прибыли [23].

- оптимизация бурения и заканчивания скважин;

Точечная перфорация продуктивных интервалов, выявленных по керну и УФ-анализу, позволяет увеличить начальные дебиты скважин и отсрочить обводнение. Выявление по керну высокопроницаемых пропластков позволяет заранее предусмотреть технологии их изоляции, предотвращая преждевременный прорыв нагнетаемой воды и экономя значительные средства на ее последующей утилизации.

- повышение коэффициента извлечения нефти (КИН).

Главный экономический эффект заключается в повышении КИН за счет принятия обоснованных решений по системе разработки и методам увеличения нефтеотдачи. Увеличение КИН даже на 1% для среднего месторождения означает дополнительные десятки миллионов долларов дохода. Например, своевременное выявление по УФ-снимкам и литологическому описанию непроницаемых барьеров позволяет скорректировать расположение нагнетательных скважин для более эффективного охвата пласта заводнением [23, 24].

Таким образом, инвестиции в качественный отбор, современная фотосъемка и высокотехнологичный анализ макроизображений керна обладают высоким эффектом, окупаясь многократно на протяжении всего жизненного цикла месторождения.

Анализ керна, и, в частности, его макроскопическое исследование с использованием изображений в видимом и ультрафиолетовом диапазонах, остается одним из основных факторов в процессе изучения коллекторов углеводородов. Современный подход позволяет трансформировать этот анализ из сугубо описательного и субъективного в количественный и объективный благодаря внедрению технологий высокоточной цифровой фотосъемки и компьютерной обработки изображений.

Данные, полученные на этом этапе, служат критически важным звеном между прямыми измерениями свойств породы в лаборатории и косвенными геофизическими измерениями в скважине. Они являются основой для корректного выделения геологических фаций, построения надежных зависимостей «керна-картаж», количественной оценки неоднородностей коллектора и, в конечном итоге, создания адекватной геологической модели.

Игнорирование макроанализа изображений керна приводит к каскадному нарастанию неопределенностей, что выливается в принятие неоптимальных решений, снижение дебитов скважин и значительное недополучение

углеводородов. Напротив, комплексный подход к анализу макроизображений позволяет существенно снизить геологические и технологические риски, оптимизировать затраты и максимизировать конечную экономическую отдачу от разработки месторождения [56]. В условиях освоения все более сложных и трудноизвлекаемых запасов роль данного метода будет только возрастать.

## **1.2. Применение методов компьютерного зрения для анализа пород на изображениях керна**

Как следует из предыдущего раздела работы, макроскопический анализ керна является очень важным инструментом для построения адекватной геологической модели месторождения. Однако, работа по исследованию образца керна сопряжена с большим количеством монотонных однотипных задач, таких как подготовка и обработка фотографий керна, например, часть процесса выглядит так: человек-оператор при помощи стандартных инструментов, в ручном режиме выделяет образец керна, обрезает его, сохраняет, именуется в соответствии с данными, указанными на изображении. Поэтому в настоящее время для анализа керна широко используются методы компьютерного анализа данных и в первую очередь – машинное обучение.

### **1.2.1. Анализ цветности пород по изображениям керна**

Одним из интересных и важных применений 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 [64–66], 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 [65] И.И. Хасанов описывает разработанное им программное обеспечение (ПО), которое делит процесс анализа керна на три этапа. На первом этапе происходит фотографирование образцов керна 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 усреднёнными для каждой ячейки параметрами. В этой таблице высчитываются такие показатели, как значения цвета в схемах RGB (цветовая модель, в которой цвет задается тремя компонентами: красным, зеленым и синим) или HSL (цветовая модель, где цвет описывается тоном, насыщенностью и светлотой). 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 гистограммы распределения этих цветов.

Основными преимуществами данной работы являются:

- внимание к таким деталям, как процесс съемки образцов керн и наличие четкого регламента для съемки;
- 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 керна, 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 керна.

Близкий к рассмотренному в работе Хасанова подход описан в [67]. 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 [67] во многом совпадают с недостатками в работе [65].

В работе [68] исследуются образцы керна, сфотографированные в видимом диапазоне в высоком разрешении. Недостающие части керна на фотографиях (к примеру, изъятые образцы в виде цилиндрических проб) заполняются согласно окружающим текстуре и структуре по методу многоточечной статистики, 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.

### 1.2.2. Анализ пород с помощью нейросетевых технологий

В настоящее время применение современных технологий, таких как компьютерное зрение, для анализа образцов керна является распространенным методом исследования. Данная тенденция, как отмечалось выше, является следствием большого объема информации, которую требуется обработать, а также сложности анализа 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 [11–13], наиболее интересные результаты которых опубликованы в [11, 12]. Так, в [11] 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 (ИмНС). 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 импульсная нейронная сеть имеет сходство с моделью обратного распространения в том, как она направляется. Однако у ИмНС есть отличия в процедуре обучения. Архитектура ИмНС, использованная автором, показана на рисунке 1.8; она состоит из входного слоя (input layer), слоя паттернов (pattern layer), слоя суммирования (summation layer) и выходного слоя (output layer). Слой паттернов имеет сходство с сетью с радиальными функциями, однако слой суммирования имеет подобие конкурентной сети.

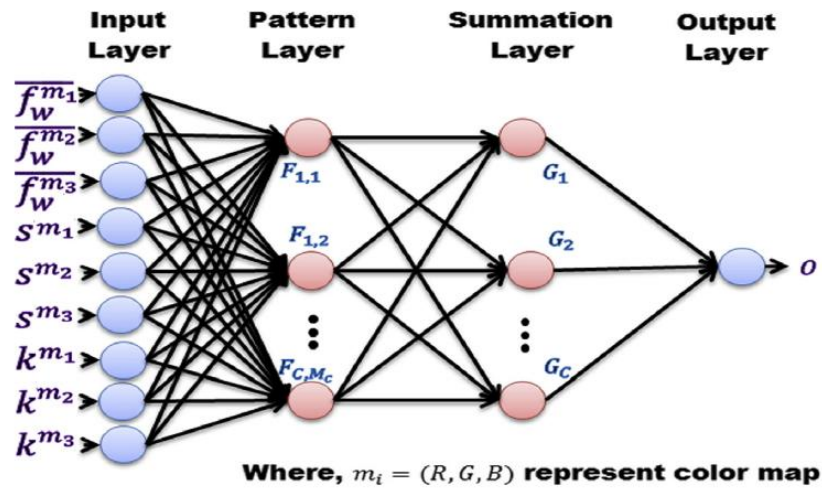


Рисунок 1.8 – Архитектура ИмНС [11]

Методология классификации, предложенная в [11], изображена на рисунке 1.9.

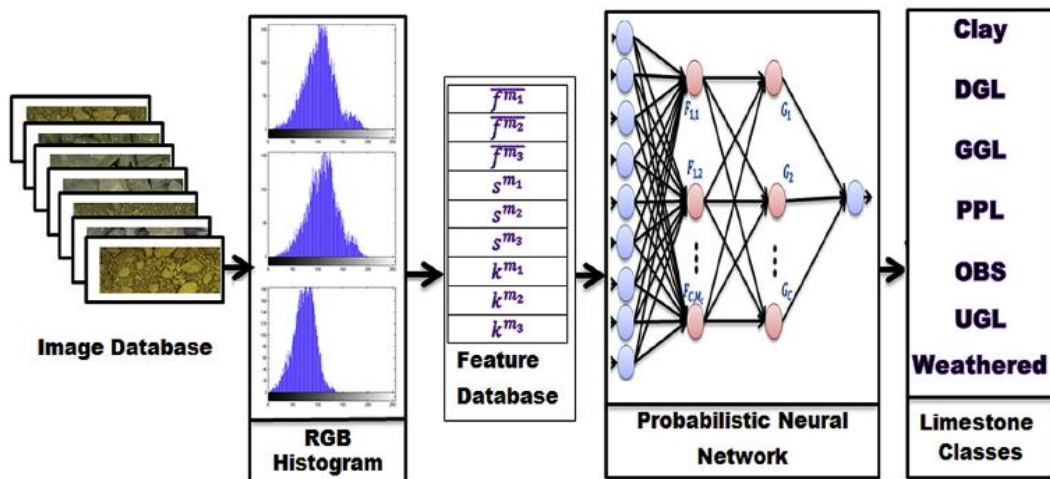


Рисунок 1.9 – Методология классификации [11]

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 заключении 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 [12] 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 рисунке 1.10.



Рисунок 1.10 – Методология системы [12]

Последующий анализ выделенных образцов угля выполняется при помощи анализа их цветности. Обученная сеть по цветности пород выделяет основные характеристики.

Еще одно важное и интересное исследование применения нейронных сетей для анализа пород рассмотрено в работе [14]. 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 деление изображения на части с заданным шагом. После этого для каждого полученного сегмента вычисляется вероятность нахождения в нём конкретного типа породы, как показано на рисунке 1.11. Кроме того, если это возможно, то еще определялись дополнительные параметры (нефтенасыщенность, пористость, проницаемость) для данного сегмента керна.




Рисунок 1.11 – Пример определения породы сегмента [14]

При проведении исследования авторами активно использовались открытые библиотеки Python для машинного обучения и обработки данных Google TensorFlow [69], Keras [70], PIL [71], NumPy [72], Scikit-Learn [73] и OpenCV [74]. Для повышения точности работы нейронной сети и уменьшения риска переобучения был применен алгоритм Dropout [75].

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 размеров изображений. 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 и определенные недостатки. К ним относятся недостаточный объем обучающей выборки; неравномерное распределение литотипов в этой выборке, поскольку сеть обрабатывает лишь 4 класса пород; а также низкая точность предсказаний для отдельных классов пород.

Нейросеть, по сути, работает с высокой точностью только при соблюдении ряда обязательных условий. Отдельно стоит упомянуть и то, что данная сеть выполняет описание керна не послойно, а с заданным шагом, что заметно влияет на результаты.

В работе [15] рассматривается создание инструмента предобработки и анализа фотографий керна. При этом важная роль отводится восстановлению поврежденных участков образцов. Известно, что такие повреждения, даже при их восстановлении с помощью окружающего контекста, 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 [16], 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 в видимом диапазоне. 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 керна нарезался на квадраты  $5 \times 5$  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 различных предварительно обученных нейронных сетей.

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 [14], в работе [16] были выделены лишь 4 класса.

Таким образом, проведенный анализ применения нейросетевых технологий для классификации пород на образцах керна 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 керна в ультрафиолетовом диапазоне, хотя ультрафиолетовое свечение позволяет выделять на изображениях нефтенасыщенные участки, что позволяет говорить о наличии флюида на том или ином интервале;
- почти все рассмотренные работы сосредоточены на том, чтобы определить тип породы, причем часто на основании цветности. Однако стоит принять во внимание, что съемка без наличия палитры может дать искажения цвета (исключением являются работы [64–66]). Тогда такие изображения не позволят достоверно определить литотип по цветности. Кроме того, цветность пород ввиду различных физических явлений, происходивших с образцами, 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.

Важным выводом также является, что во всех рассмотренных работах задача классификации выполнялась примерно одинаково:

1. На изображении с несколькими образцами керна обрезался конкретный образец, причем неровности, края образца, тоже обрезались.
2. Далее выбирался размер окна, и обрезанный керн, согласно этим размерам, делился на интервалы.
3. Исследования проводились отдельно внутри каждого интервала, в результате чего определялся тип породы в интервале.

Такой алгоритм классификации имеет существенные недостатки, так как:

- при обрезке теряются важные для анализа участки керна;
- 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.

### **1.3. Выводы по первой главе**

При использовании методов машинного обучения первым шагом к повышению точности и ускорению обработки фотографий керна является введение автоматической сегментации образцов. Это снимает с геолога обязанность вручную вырезать каждый кусок породы – а ведь за год через лабораторию проходит тысячи снимков, по шесть кусков керна на каждом.

Сегментация позволяет сохранить неровности и форму керна, которые в традиционных методах просто обрезаются, как показано на рисунке 1.12, а значит, улучшить качество последующего анализа. Кроме того, этот подход эффективно работает даже с сильно раздробленными фрагментами, где ручная обрезка особенно трудоёмка.



Рисунок 1.12 – Пример потери части керна при обрезке во время анализа стандартными средствами

Кроме того, сегментация служит основой для выявления нефтенасыщенных зон. Однако для решения данной задачи необходимо сегментировать не только фотографии керна в видимом диапазоне, но также и в ультрафиолетовом. Так на первом этапе на фотографиях в видимом диапазоне необходимо отделить породу от фона и других объектов – по сути, решить задачу бинарной классификации («пиксель порода» и «пиксель не порода»). А уже затем провести сегментацию фотографий в ультрафиолете. Для этого прежде всего необходимо иметь сбалансированную архитектуру нейросети, обеспечивающую надежную сегментацию образцов керна.

Исходя из вышеизложенного, сформулируем постановку задачи. Необходимо получить архитектуру нейронной сети для надежной сегментации образцов керна, разработать и реализовать алгоритм оценки нефтеносности по фотографиям керна в видимом и ультрафиолетовом диапазоне на основе применения полученной нейронной сети для сегментации, построить информационную систему для исследования и хранения керна.

## **Глава 2. Разработка гибридной архитектуры нейронной сети для семантической сегментации образцов пород**

После детального анализа в предыдущей главе, где были рассмотрены как фундаментальная значимость керновых исследований, так и существующие ограничения традиционных и полуавтоматических методов анализа, мы подходим к ключевому этапу настоящей работы – созданию современного и эффективного вычислительного инструмента. Основой для любой последующей автоматизированной интерпретации геологических данных, будь то классификация литотипов или оценка нефтенасыщенности, является задача семантической сегментации. Этот процесс представляет собой не просто нахождение объектов на изображении, а их пиксельно-точное оконтуривание, что позволяет разделить изображение на осмысленные, с геологической точки зрения, области. В нашем случае это означает точное отделение образцов породы от всего остального, что попало в кадр: деревянных ящиков, измерительных лент, маркировок и прочих технических артефактов.

Качественное решение этой, на первый взгляд, подготовительной задачи имеет огромное прикладное значение. Во-первых, оно полностью устраняет трудоемкий и подверженный ошибкам этап ручной обрезки изображений. Во-вторых, сохраняет естественную, часто неправильную и обломанную форму керна, информация о которой безвозвратно теряется при грубой прямоугольной обрезке. Наконец, точная сегментация является абсолютно необходимым фундаментом для всех последующих, более сложных алгоритмов анализа, которые будут рассматриваться в следующей главе.

Целью настоящей главы является получение наиболее эффективной архитектуры нейронной сети, показывающей достаточные для промышленного использования результаты семантической сегментации как монолитных, так и сильно раздробленных образцов пород на макрофотографиях керна. Работа в рамках главы выстроена как последовательное исследование: сначала проводится

сравнительный анализ существующих архитектур для выбора наиболее подходящей, затем детально исследуется ее поведение на сложных, раздробленных образцах, после чего делается вывод о возможности ее использования в рамках задач, решаемых в настоящей работе. Если существующая наиболее эффективная архитектура не показала достаточные результаты, выполняется разработка и валидация новой гибридной модели специально для задачи сегментации пород на изображениях керна.

## **2.1. Поиск и обоснование выбора архитектуры сети**

Современное компьютерное зрение предлагает десятки различных архитектур для решения задачи семантической сегментации [76-84]. Их выбор – это всегда поиск оптимального компромисса между точностью предсказания, скоростью работы и объемом вычислительных ресурсов (в первую очередь, видеопамяти), которые требуются для обучения и последующего применения модели. Чтобы этот выбор был не умозрительным, а строго обоснованным, был спланирован и проведен комплексный вычислительный эксперимент.

В рамках работы в настоящем подразделе были поставлены задачи:

1. Сформировать и промаркировать репрезентативный датасет макрофотографий керна.
2. Выбрать наиболее оптимальные архитектуры из существующих для решения задачи семантической сегментации образцов пород.
3. Настроить и обучить модели по выбранным архитектурам.
4. Сравнить модели по метрикам качества (Dice, IoU, Precision, Recall, mAP) и вычислительным характеристикам (время инференса, объём памяти).
5. Определить наиболее оптимальную модель.

### **2.1.1. Методология эксперимента и подготовка данных**

В данном подразделе описываются этапы формирования датасета, его разметки и подготовки данных.

### *Формирование и разметка датасета*

В качестве исходного материала для обучения модели были использованы макрофотографии образцов керна, сделанные в лабораторных условиях при естественном освещении. Всего собрано 319 оригинальных снимков в разрешении  $4000 \times 4000$  пикселей.

Аннотация снимков осуществлялась вручную в программе Adobe Photoshop и была провалидирована экспертами. Для каждого изображения была создана бинарная маска. Независимо от того, как каждая маска была составлена, специалисты затем совместно проводили согласование всех выявленных расхождений. Благодаря такому подходу разметка получилась максимально точной и единообразной.

### *Аугментация данных*

Обучение глубоких нейронных сетей требует большого объема разнообразных данных. Чтобы повысить обобщающую способность модели, то есть ее умение работать с новыми, ранее не встречавшимися изображениями, и расширить обучающую выборку, был использован следующий набор техник аугментации [85]:

- геометрические преобразования: горизонтальные и вертикальные отражения, случайные повороты на небольшие углы (в пределах  $\pm 10^\circ$ ), а также незначительное масштабирование (от 90% до 110%). Эти методы позволяют обучить сеть быть инвариантной к положению керна в кадре и его размеру;
- фотометрические преобразования: небольшие изменения яркости и контрастности (в пределах  $\pm 10\%$ ). За счет этого модель лучше адаптируется к возможным изменениям условий освещения при съемке.

За счет таких преобразований модель становится устойчивее к изменению положения керна в кадре, к вариациям освещения и небольшим деформациям изображений.

### *Подготовка к обучению*

Весь массив данных был разделен в соотношении 80% на 20% на обучающую и тестовую выборки соответственно. Перед подачей в нейронную сеть все изображения проходили обязательный этап нормализации: интенсивность каждого пикселя приводилась к стандартному диапазону  $[0, 1]$ . Эта сравнительно простая операция заметно ускоряет сходимость модели и делает процесс обучения более стабильным.

Аугментации применялись только к обучающей выборке в ходе тренировки, тогда как тестовая выборка сохранялась в исходном, неизменном виде для объективной оценки качества модели.

### **2.1.2. Сравнительный анализ архитектур**

Современная область глубокого обучения предлагает очень большое и постоянно растущее разнообразие архитектур нейронных сетей [76-85]. В основу сравнительного анализа были положены архитектуры энкодер-декодер типа, концептуально близкие к парадигме U-Net, поскольку модели данного класса относятся к числу наиболее широко применяемых и хорошо апробированных решений в задачах сегментации изображений. Для рассматриваемой задачи такой выбор представляется обоснованным, так как подобные архитектуры позволяют эффективно сочетать извлечение контекстной информации с сохранением пространственной детализации, что особенно важно при сегментации сильно фрагментированных изображений пород. Наряду с ними в исследование были включены модели сегментации, основанные на иной архитектурной парадигме и ориентированные на практический компромисс между качеством выделения объектов и вычислительной эффективностью. Для практического применения разрабатываемой системы необходимо, чтобы сегментация выполнялась за приемлемое время; в противном случае использование системы, описанной в главе 4, в реальных условиях оказывается затруднительным. В итоге, для анализа были выбраны следующие архитектуры [77, 79, 82, 84]:

1. U-Net - стандарт для задач семантической сегментации, особенно в биомедицинской сфере, где упор делается на очень детализированные изображения, как и в случае с породами. Ее U-образная архитектура состоит из двух симметричных путей: сжимающего (энкодера), который последовательно извлекает признаки и уменьшает пространственное разрешение, и расширяющего (декодера), который затем восстанавливает изображение до исходного размера, формируя маску сегментации. Ключевая инновация U-Net – это пропускные связи, напрямую передающие детализированную информацию с ранних слоев энкодера на соответствующие слои декодера. За счет этого модель не «забывает» точные контуры и мелкие детали объектов в процессе глубокого анализа.
2. U-Net++ - дальнейшее развитие и усложнение архитектурных идей, заложенных в U-Net. Вместо обычных пропускных связей здесь используется целая система вложенных и более плотных связей между энкодером и декодером. Такая организация нужна для того, чтобы уменьшить семантический разрыв между картами признаков энкодера и декодера и при этом объединять информацию, поступающую с разных уровней детализации. Включение этой модели в анализ дает возможность проверить важный исследовательский вопрос: приводит ли усложнение пропускных связей и увеличение числа параметров к действительно заметному росту качества сегментации в нашей задаче и насколько это улучшение оправдано с точки зрения вычислительных затрат.
3. SegNet - еще один представитель энкодер-декодерных архитектур, но в данном случае основной упор сделан именно на вычислительную эффективность. Если в U-Net по пропускным связям передаются целые карты признаков, то в SegNet подход устроен иначе: в процессе пулинга в энкодере сохраняются только индексы максимальных элементов. Затем уже в декодере эти индексы используются при операции обратного пулинга, за счет чего удается восстановить пространственную структуру изображения при значительно

меньших затратах памяти и вычислений. Поэтому анализ SegNet важен в том числе и с практической точки зрения, так как позволяет оценить, насколько оправдан компромисс между скоростью работы и точностью сегментации, и можно ли в нашей задаче пожертвовать частью точности ради более быстрой обработки данных.

4. YOLOv8-seg и YOLOv11-seg – эти модели представляют совершенно иную парадигму. Изначально разработанные для задачи детекции объектов в реальном времени, они были адаптированы для сегментации. В отличие от пиксельно-точных сегментаторов, их архитектура нацелена на максимально быстрый однопроходный анализ всего изображения для одновременного предсказания и ограничивающих рамок, и масок объектов. Анализ этих моделей, особенно более современной версии YOLOv11-seg с ее блоками внимания, представляет ценность не только с точки зрения сравнения метрик (что позволяет проверить гипотезу: может ли архитектура, изначально созданная для улавливания общего контекста и быстрого нахождения объектов, быть конкурентоспособной в задаче, требующей высокой точности границ), но и с позиции возможного заимствования отдельных архитектурных идей при дальнейшем совершенствовании собственной модели.

Результаты теоретического анализа отобранных архитектур приведены в таблице 2.1.

Таблица 2.1 – Основные характеристики проанализированных архитектур [84]

Архитектура	Основная идея	Плюсы	Минусы
U-Net	Энкодер-декодер и пропускные связи	Простота, детальная маска	Семантический разрыв между низкоуровневыми и высокоуровневыми представлениями Требовательна к памяти
U-Net++	Вложенные плотные пропускные связи	Улучшенная агрегация признаков	Рост памяти относительно базовой U-Net при обработке изображения (+60 %) Скорость инференса ниже Требовательна к памяти

*Продолжение таблицы 2.1*

Архитектура	Основная идея	Плюсы	Минусы
SegNet	Индексы пула в декодере	Быстрый инференс Экономия памяти	Потеря пространственного разрешения и граничных деталей
YOLOv8-seg	Одностадийный детектор	Компромисс между качеством и вычислительной эффективностью	«Размытые» границы масок
YOLOv11-seg	Расширенная версия YOLOv8-seg с блоками внимания	Большая точность относительно YOLOv8-seg	Большой инференс и расход памяти относительно YOLOv8-seg

Все перечисленные модели были обучены на подготовленном датасете в идентичных условиях. Для оценки их производительности использовался стандартный набор метрик: коэффициент Дайса (Dice) и индекс Жаккара (IoU) для оценки точности перекрытия предсказанной и эталонной масок, Precision и Recall для оценки ложноположительных и ложноотрицательных ошибок модели, а также время инференса и пиковое потребление видеопамати.

*Настройка гиперпараметров*

При обучении всех сетей использовался размер батча 8, оптимизатор Adam с параметрами  $\beta_1=0.9$  (коэффициент экспоненциального усреднения для первого момента градиента) и  $\beta_2=0.999$  (коэффициент экспоненциального усреднения для второго момента) и начальной скоростью обучения  $1 \cdot 10^{-3}$ . Для адаптации скорости обучения в процессе работы применяется планировщик ReduceLROnPlateau с коэффициентом уменьшения 0.5 и терпением (patience) на 3 эпохи без улучшения.

В качестве функции потерь для U-Net и U-Net++ использовалась комбинация Binary Cross-Entropy и DiceLoss, что способствовало более точной сегментации. Для SegNet в качестве функции потерь были выбраны CrossEntropy и IoULoss, чтобы одновременно учитывать ошибку классификации каждого пикселя и качество перекрытия сегментированных областей. В случае YOLO-моделей применялась убывающая комбинация MaskLoss и Focal Loss.

Для каждой модели задавалось предельное число эпох обучения, однако фактическая длительность обучения определялась механизмом ранней остановки:

при отсутствии улучшения качества обучение прекращалось. Для последующего анализа сохранялась контрольная точка модели, показавшая наилучший результат.

### 2.1.3. Метрики качества сегментации

Для оценки точности сегментации макрофотографий образцов керна в настоящей работе использовались следующие метрики [85-89]:

#### *Коэффициент сходства Дайса (Dice)*

Коэффициент Дайса считает степень совпадения между множеством предсказанных пикселей и множеством эталонных пикселей:

$$Dice = \frac{2 \cdot TP + \varepsilon_1}{2 \cdot TP + FP + FN + \varepsilon_1}, \quad (2.1)$$

где  $Dice$  – коэффициент сходства Дайса,  $TP$  – число истинно-положительных пикселей,  $FP$  – число ложноположительных пикселей,  $FN$  – число ложноотрицательных пикселей,  $\varepsilon_1$  – smoothing константа для Dice.

Коэффициент принимает значения от 0 до 1: чем ближе значение к 1, тем точнее совпадают маски, а значение 1 означает их полное совпадение. В бинарных задачах сегментации эта метрика особенно полезна при несбалансированном соотношении классов, поскольку хорошо показывает качество выделения целевой области в ситуациях, когда она значительно меньше фона.

#### *Индекс Жаккара (IoU)*

Индекс Жаккара – это отношение площади пересечения, предсказанной и эталонной масок к площади их объединения:

$$IoU = \frac{TP + \varepsilon_2}{TP + FP + FN + \varepsilon_2}, \quad (2.2)$$

где  $IoU$  – индекс Жаккара,  $TP$  – число истинно-положительных пикселей,  $FP$  – число ложноположительных пикселей,  $FN$  – число ложноотрицательных пикселей,  $\varepsilon_2$  – smoothing константа для IoU.

Как и коэффициент Дайса, индекс Жаккара принимает значения от 0 до 1. Обычно значение индекса оказывается ниже, чем коэффициента Дайса, поэтому оба показателя целесообразно рассматривать совместно, чтобы получить более

полное представление о качестве модели. Индекса Жаккара широко используется в задачах детектирования и сегментации, поскольку позволяет единообразно сравнивать различные модели.

### *Precision*

Суть данной метрики в том, что она показывает долю корректно предсказанных пикселей породы керна среди всех пикселей, отнесённых моделью к изображению:

$$Precision = \frac{TP}{TP+FP}, \quad (2.3)$$

где *Precision* – точность (доля корректных пикселей среди предсказанных как целевой класс).

### *Recall*

Recall отражает, какую часть истинных пикселей керна удалось выявить:

$$Recall = \frac{TP}{TP+FN}, \quad (2.4)$$

где *Recall* – полнота (доля найденных целевых пикселей среди истинных целевых пикселей).

### *Метрики для YOLO*

Для одностадийных моделей YOLOv8-seg и YOLOv11-seg дополнительно рассчитывалась mAP при пороге перекрытия 0,5 (mAP 50). mAP оценивает среднее значение площади под кривой Precision–Recall по всем классам (в нашей задаче – один класс «кern»). Высокое значение mAP свидетельствует о сбалансированности модели и её стабильности на различных уровнях уверенности предсказаний.

$$mAP = \frac{1}{K} \cdot \sum_{k=1}^K AP_k, \quad (2.5)$$

где *mAP* – средняя по классам величина *AP*, *AP<sub>k</sub>* – средняя точность для класса *k*, *K* – число классов.

### 2.1.4. Результаты эксперимента

В результате глубокого анализа были получены данные, представленные в таблице 2.2.

Таблица 2.2 – Метрики качества сетей в задаче сегментации образцов пород

Модель	Dice	IoU	Precision	Recall	mAP	Время инференса, сек	GPU RAM, ГБ
U-Net	0,910	0,862	0,89	0,93	–	0,15	4,0
U-Net++	0,920	0,870	0,90	0,94	–	0,18	6,5
SegNet	0,880	0,810	0,85	0,92	–	0,12	3,8
YOLOv8-seg	0,895	0,845	0,91	0,89	0,75	0,22	7,2
YOLOv11-seg	0,902	0,853	0,92	0,90	0,80	0,25	8,0

Классическая архитектура U-Net показала очень хорошую сбалансированность, достигнув Dice = 0,910 и IoU = 0,862. Во многом это связано с пропускными связями, которые напрямую передают пространственную информацию высокого разрешения от энкодера к декодеру. Для геологической задачи это особенно важно: признаки, описывающие тонкие границы зерен, микротрещины и мелкие каверны, которые «размываются» и теряются в глубоких слоях энкодера, в области наиболее сжатого представления признаков (bottleneck), затем восстанавливаются в декодере. За счет этого модель точнее выделяет отдельные раздробленные части породы, что и видно по высоким значениям Dice и IoU.

Умеренное потребление ресурсов (4,0 GB GPU RAM) и быстрое время инференса (0,15 с) делают U-Net вполне практичным выбором в тех случаях, когда требуется обрабатывать сотни или тысячи изображений керна. Снижение точности по сравнению с U-Net++ можно, по-видимому, связать с тем, что на более сложных текстурах, например у фрагментированного образца, модель иногда все же пропускает отдельные участки, предпочитая те области, которые определяются более уверенно.

Что касается U-Net++, то вложенные и плотные пропускные связи дают возможность агрегировать признаки, относящиеся к разным семантическим уровням. Из-за этого в декодер поступает не одна, а сразу несколько карт признаков из энкодера, причем каждая из них проходит разное число сверточных блоков. За счет такой схемы модель обучается более гибко и, в целом, лучше улавливает нюансы границ объектов. На этом фоне выглядит вполне закономерным рост метрик до  $Dice = 0,920$  и  $IoU = 0,870$ . Прирост по Dice в подобных задачах может оказаться решающим, если от точности оценки зависят критические геологические или инженерные выводы.

Однако у этой высокой точности есть и своя цена, причем в рамках настоящей работы это уже серьезный минус. Существенно более сложный путь прохождения градиентов и большой объем хранимых карт признаков приводят к резкому росту требований к ресурсам: 6,5 ГБ памяти видеопроцессора (+62,5% к U-Net) и, что более важно, 0,18 с (+20% к U-Net) на инференс. Если требуется построение потоковой системы анализа ядра в реальном времени, такая модель выглядит уже менее предпочтительной.

SegNet демонстрирует самый быстрый инференс (0,12 с) и минимальное потребление памяти (3,8 ГБ памяти видеопроцессора). С вычислительной точки зрения такой подход очень эффективен, но в этом же состоит и его главный недостаток. Поскольку сохраняются только индексы, модель теряет заметную часть информации о локальном окружении пикселя. Из-за этого восстановленные маски получаются более «рваными», а их границы - менее точными, что напрямую отражается в самых низких значениях Dice (0,880) и IoU (0,810). Для задач, где важно лишь примерное расположение породы, SegNet еще может быть оправдан, но для точного анализа его точности уже недостаточно.

Высокие значения Precision (0,91-0,92) у обеих моделей YOLO показывают, что в тех случаях, когда модель идентифицирует область как породу, она делает это с высокой степенью уверенности. Это в целом характерно для детекторов, ориентированных на минимизацию ложных срабатываний.

Однако основной недостаток этих моделей связан с качеством самой маски. В YOLO-архитектурах она нередко формируется на основе карт признаков с более низким разрешением по сравнению с декодером U-Net. При этом основная задача состоит в локализации объекта, тогда как точное оконтуривание остается вторичным. Из-за этого границы получаются несколько «размытыми» или огрубленными, и именно это снижает интегральные метрики пересечения, такие как Dice и IoU, до уровня  $\sim 0,90$  и  $\sim 0,85$  соответственно, что уступает U-Net.

### **2.1.5. Обоснование выбора U-Net для дальнейшего исследования**

Сравнительный анализ позволяет довольно уверенно разделить исследованные архитектуры по критериям точности и эффективности [85-91]:

- высокая точность: U-Net++ показывает наилучшее качество сегментации за счет более сложной архитектуры пропускных связей, хотя по эффективности эта модель все же уступает;
- высокая скорость: SegNet остается самым быстрым и экономичным вариантом, но его точности уже недостаточно для количественного анализа, поскольку при восстановлении пространственного разрешения теряется часть деталей;
- альтернативный подход: YOLO-seg в целом хорошо справляется с детекцией пород как объектов, что видно по высоким значениям Precision и mAP, однако нужной точности границ не обеспечивает. При этом YOLO-seg также требует заметного объема ресурсов;
- оптимальный компромисс: классическая U-Net, по сути, оказывается наиболее сбалансированным решением. По точности она лишь немного уступает U-Net++, но вычислительных затрат требует заметно меньше. Ее архитектура хорошо сохраняет тонкие геологические структуры, и именно поэтому она выглядит наиболее удачной отправной точкой.

Несмотря на достаточно высокие значения метрик, полученные результаты нельзя считать полностью достаточными для практического применения. Даже

лучшая из исследованных моделей обеспечивает  $Dice = 0,920$  и  $IoU = 0,870$ , что указывает на сохраняющееся расхождение между предсказанной и эталонной масками. Для рассматриваемой задачи это имеет принципиальное значение, поскольку при анализе изображений пород существенны не только общая площадь совпадения масок, но и точность воспроизведения тонких границ, мелких каверн, микротрещин и взаимной связности выделяемых структур. Поэтому даже сравнительно небольшие локальные ошибки сегментации в данном случае не могут рассматриваться как несущественные, а достигнутый уровень точности следует признать недостаточным для надежного практического использования без дальнейшего совершенствования модели.

Тем не менее, проведенное исследование достаточно убедительно показывает, что для задачи семантической сегментации в образцах керна, где важны и точность оконтуривания, и приемлемая скорость обработки, и умеренные требования к вычислительным ресурсам, классическая архитектура U-Net оказывается наиболее подходящей моделью из рассмотренных.

Таким образом, в дальнейшей работе для решения задачи семантической сегментации образцов керна было решено взять U-Net архитектуру за основу и модифицировать ее для получения более высоких метрик при работе с образцами пород.

## **2.2. Влияние раздробленности керна на результаты сегментации**

Проведенный в предыдущем разделе сравнительный анализ показал, что архитектуру U-Net можно взять в качестве оптимальной отправной точки для дальнейших исследований, поскольку именно она дала наиболее сбалансированное сочетание точности и вычислительных затрат. Но выбор базовой модели сам по себе решает далеко не все - это, скорее, только начало дальнейшей работы. Чтобы в итоге получить действительно робастную систему, пригодную для применения в реальных промышленных условиях, нужно отдельно оценить ее уязвимости перед

ключевыми вызовами. В нашем случае главным таким вызовом остается вариативность степени раздробленности керна.

На практике образцы пород варьируются от цельных, монолитных кусков породы до фрагментированных, состоящих из множества мелких, хаотично расположенных фрагментов. Такая неоднородность данных представляет собой серьезное испытание для любой архитектуры, поскольку обилие мелких объектов со сложными границами может приводить к заметному снижению качества сегментации.

Прежде чем переходить к разработке гибридной модели, требуется провести отдельное исследование и количественно оценить, как именно степень раздробленности керна влияет на производительность выбранной базовой архитектуры U-Net и ее конкурентов. Задачами этого анализа являются:

Во-первых, выявление архитектурных недостатков базовой U-Net при работе со сложными, сильно раздробленными образцами пород.

Во-вторых, выявление архитектурных решений, присутствующих в других моделях (например U-Net++, YOLO), которые демонстрируют наибольшую эффективность при работе с фрагментированными образцами породы и могут быть использованы для последующей модификации.

Для проведения эксперимента весь исходный датасет изображений был разделен на три группы:

- монолитные образцы: группа, содержащая исключительно изображения цельных, неповрежденных фрагментов керна;
- фрагментированные образцы: группа, включающая как слабо-, так и сильно раздробленные образцы;
- смешанная группа: сбалансированный набор, состоящий из всех типов образцов в равной пропорции, что имитирует наиболее общий случай.

Для каждой из этих групп была выполнена аугментация для повышения обобщающей способности моделей и получения наиболее стабильных результатов.

### 2.2.1. Анализ U-Net архитектуры

Первой для детального анализа была выбрана архитектура U-Net, показавшая сбалансированные результаты в предыдущих экспериментах. Обучение и валидация модели проводились последовательно на каждой из трех подготовленных групп данных. Результаты метрик для смешанного, монолитного и фрагментированного датасетов представлены в таблицах 2.3, 2.4 и 2.5 соответственно.

Таблица 2.3 – Метрики U-Net для смешанного датасета

Epoch	Train Loss	Train Dice	Train IoU	Val Loss	Val Dice	Val IoU
1	0,4337	0,8009	0,6966	0,6199	0,8260	0,7149
2	0,2603	0,9010	0,8264	0,4599	0,8249	0,7127
3	0,2155	0,9256	0,8668	0,2769	0,8932	0,8131
4	0,1984	0,9355	0,8818	0,1987	0,9419	0,8934
5	0,1886	0,9357	0,8846	0,1766	0,9427	0,8946
6	0,1839	0,9382	0,8865	0,1729	0,9497	0,9057
25	0,1115	0,9614	0,9271	0,1319	0,9565	0,9185

Таблица 2.4 – Метрики U-Net для монолитного датасета

Epoch	Train Loss	Train Dice	Train IoU	Val Loss	Val Dice	Val IoU
1	0,3866	0,8359	0,7389	0,4597	0,8451	0,7430
2	0,2330	0,9315	0,8765	0,3253	0,8633	0,7697
3	0,2090	0,9398	0,8912	0,1912	0,9457	0,9000
4	0,1944	0,9472	0,9032	0,1699	0,9604	0,9240
5	0,1783	0,9530	0,9132	0,1651	0,9619	0,9269
6	0,1666	0,9577	0,9213	0,1600	0,9634	0,9297
25	0,0774	0,9810	0,9628	0,1108	0,9625	0,9294

Таблица 2.5 – Метрики U-Net для фрагментированного датасета

Epoch	Train Loss	Train Dice	Train IoU	Val Loss	Val Dice	Val IoU
1	0,4261	0,8262	0,7242	0,4914	0,8142	0,6962
2	0,2504	0,9247	0,8627	0,2448	0,9356	0,8809
3	0,2198	0,9378	0,8843	0,2163	0,9437	0,8949
4	0,2039	0,9450	0,8966	0,2036	0,9501	0,9064
5	0,1941	0,9482	0,9023	0,1986	0,9506	0,9071
6	0,1870	0,9510	0,9072	0,1974	0,9525	0,9105
25	0,1097	0,9617	0,9267	0,1457	0,9574	0,9197

Для наглядного сопоставления динамики обучения были построены графики, приведенные на рисунках 2.1 и 2.2, изменения метрик Val Dice и Val IoU для всех трех групп данных.

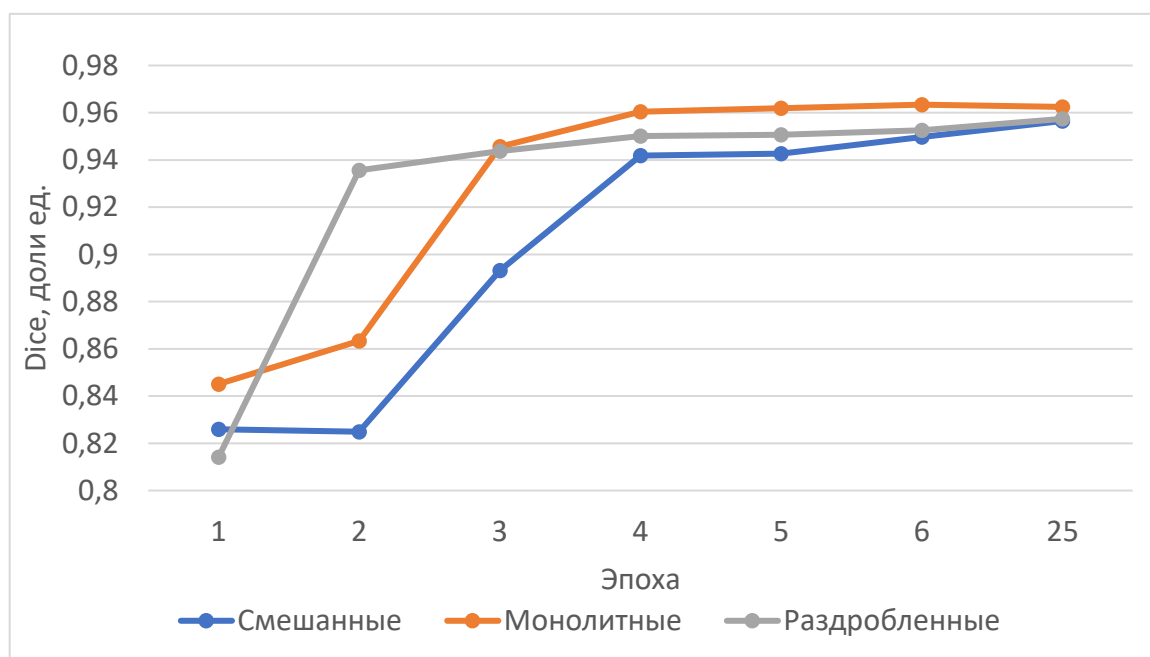


Рисунок 2.1 – Диаграмма Dice для U-Net




Рисунок 2.2 – Диаграмма IoU для U-Net

Таким образом, по проведенному анализу можно сделать следующие заключения относительно работы оригинальной архитектуры U-Net:

1. Подтверждена чувствительность к сложности данных: как и ожидалось, наилучшие и наиболее стабильные результаты в ходе обучения показывает модель, обученная на монолитном датасете. Лучшее значение Val Dice для нее достигает 0,9634 на 6-й эпохе, что выше соответствующих результатов для смешанного и фрагментированного датасетов. Простые и четко очерченные границы цельных образцов оказываются для U-Net наиболее легкой задачей. В то же время модель, обученная на смешанном датасете, демонстрирует наиболее медленную сходимость, особенно на начальных эпохах (Val Dice = 0,8260 на 1-й эпохе), что можно объяснить необходимостью одновременно выделять признаки объектов с существенно различающейся морфологией.
2. Сегментация фрагментированных образцов является более сложной задачей: модель, обученная на фрагментированном датасете, демонстрирует устойчивый рост качества на протяжении обучения: Val Dice увеличивается с 0,8142 до 0,9574, а Val IoU - с 0,6962 до 0,9197. Это свидетельствует о том, что U-Net в целом успешно адаптируется к сегментации раздробленных образцов. Вместе с тем итоговые метрики на фрагментированном датасете остаются

несколько ниже, чем на монолитном, что указывает на более высокую сложность задачи и наличие ограничений базовой архитектуры при работе с мелкими и сложно организованными фрагментами.

- U-Net обладает удовлетворительной обобщающей способностью, но не является оптимальной для сильно разнородных данных: к концу обучения разница между моделями, обученными на разных типах датасетов, становится небольшой. Это говорит о том, что при достаточном количестве эпох U-Net способна выучить признаки как монолитных, так и фрагментированных образцов. Однако сохранение пусть и небольшого, но устойчивого разрыва в качестве подтверждает, что архитектура не является оптимальной для работы с сильно гетерогенными данными и сохраняет потенциал для улучшения именно в аспекте работы с раздробленным керном.

### 2.2.2. Анализ U-Net++ архитектуры

Следующей для исследования была выбрана U-Net++. Основная гипотеза состояла в том, что ее архитектурные особенности, а именно вложенные и плотные пропускные связи, обеспечат модели повышенную устойчивость к проблеме фрагментации керна. Эксперимент проводился по аналогии с предыдущим: модель обучалась и валидировалась на трех датасетах - монолитном, раздробленном и смешанном. Метрики качества обучения для каждого случая приведены в таблицах 2.6, 2.7, 2.8.

Таблица 2.6 – Метрики U-Net++ для смешанного датасета

Epoch	Train Loss	Train Dice	Train IoU	Val Loss	Val Dice	Val IoU
1	0,5986	0,6892	0,5522	0,6980	0,6287	0,4889
2	0,4394	0,8367	0,7298	0,6629	0,6605	0,5214
3	0,3370	0,8747	0,7853	0,5019	0,8353	0,7277
4	0,2626	0,9030	0,8311	0,2992	0,8909	0,8110
5	0,2170	0,9170	0,8514	0,2046	0,9304	0,8734
6	0,1830	0,9279	0,8682	0,1711	0,9374	0,8852

Таблица 2.7 – Метрики U-Net++ для монолитного датасета

Epoch	Train Loss	Train Dice	Train IoU	Val Loss	Val Dice	Val IoU
1	0,5914	0,7357	0,6058	0,6834	0,8190	0,7061
2	0,4115	0,8455	0,7452	0,5479	0,8509	0,7517
3	0,3097	0,9099	0,8406	0,2830	0,9224	0,8608
4	0,2346	0,9367	0,8832	0,1817	0,9515	0,9088
5	0,1698	0,9450	0,8996	0,1451	0,9418	0,8926
6	0,1101	0,9570	0,9184	0,1159	0,9471	0,9022

Таблица 2.8 – Метрики U-Net++ для фрагментированного датасета

Epoch	Train Loss	Train Dice	Train IoU	Val Loss	Val Dice	Val IoU
1	0,5241	0,7278	0,5909	0,6815	0,6982	0,5479
2	0,3422	0,8668	0,7716	0,4829	0,8613	0,7638
3	0,2476	0,9058	0,8312	0,2375	0,9262	0,8644
4	0,1849	0,9261	0,8640	0,1867	0,9307	0,8717
5	0,1559	0,9295	0,8699	0,1579	0,9382	0,8853
6	0,1350	0,9353	0,8798	0,1492	0,9438	0,8949

Для наглядного сопоставления были построены графики, приведенные на рисунках 2.3, 2.4.




Рисунок 2.3 – Диаграмма Dice для U-Net++




Рисунок 2.4 – Диаграмма IoU для U-Net++

Результаты эксперимента с U-Net++ подтверждают выдвинутую гипотезу. По полученным данным можно сделать следующие заключения о работе U-Net++:

1. Высокая устойчивость к фрагментации: главный вывод здесь в том, что различия в качестве сегментации между монолитными и фрагментированными образцами остаются совсем небольшими. На 6-й эпохе обучения разрыв по метрике Val Dice составляет всего 0,33% (0,9471 против 0,9438), а по Val IoU - 0,73% (0,9022 против 0,8949). Это дает основания считать, что U-Net++ лучше справляется с сегментацией сложных, мелкоструктурированных объектов, чем классическая U-Net.
2. Эффективность вложенных плотных пропускных связей: высокая устойчивость модели объясняется одной из главных особенностей U-Net++ - организацией вложенных плотных пропускных связей. Если в классической U-Net используются более прямолинейные пропускные связи между энкодером и декодером, то здесь обмен признаками устроен заметно сложнее и гибче. Такая схема дает возможность объединять карты признаков, полученные на разных семантических уровнях энкодера, и тем самым уменьшать разрыв между обобщенными контекстными признаками глубоких слоев и более точными, детализированными признаками ранних уровней. В

результате модель лучше сохраняет и общую структуру объекта, и мелкие детали его границ. За счет этого она одинаково уверенно справляется как с сегментацией крупных монолитных участков, так и с выделением множества мелких фрагментов, что и отражается в стабильно высоких значениях метрик на разных типах данных.

3. Потенциал как универсального решения: несмотря на то, что модель на смешанном датасете традиционно медленнее сходится на начальных этапах, к 6-й эпохе она достигает Val Dice 0,9374, уступая лидеру (модели на монолитных данных) всего около 1%. Это подчеркивает высокий потенциал архитектуры U-Net++ для создания универсальной системы, способной эффективно работать с образцами керна любой степени раздробленности без предварительной сортировки.

### 2.2.3. Анализ Yolo

Аналогичное исследование было проведено и для архитектуры YOLO. Динамика обучения модели на монолитных и раздробленных датасетах представлена на рисунках 2.5 и 2.6.

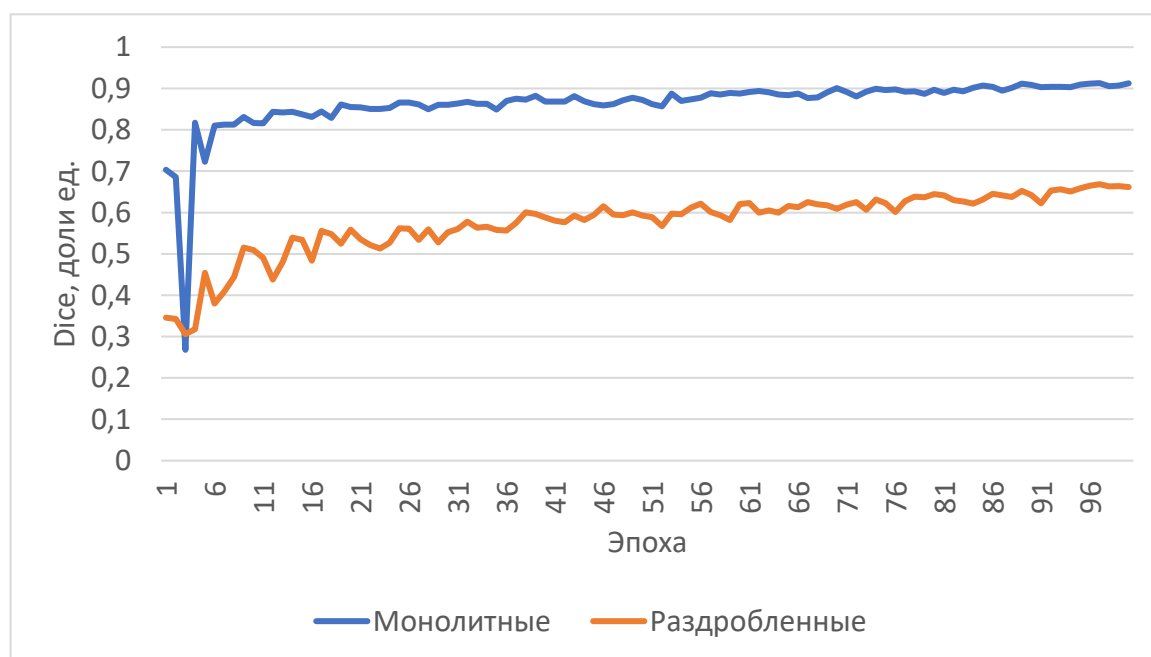


Рисунок 2.5 – Диаграмма Dice для Yolo




Рисунок 2.6 – Диаграмма IoU для Yolo

Анализ полученных результатов показывает выраженный разрыв в производительности YOLO на двух типах выборок. Это напрямую связано с архитектурными особенностями и ограничениями данного подхода.

#### *Уверенная работа с монолитными образцами*

На датасете с монолитными образцами модель показывает достаточно ровный рост метрики и к концу обучения выходит на значение IoU около 0,91. Это связано с тем, что сегментация цельного крупного объекта по своей постановке близка к той задаче, для которой YOLO изначально и создавалась - детекции объектов. В таких условиях модель довольно эффективно использует глобальный контекст изображения, быстро локализует основной объект - керн и формирует для него маску. Когда границы объекта остаются сравнительно простыми и предсказуемыми, такой механизм, в целом, работает уверенно.

#### *Систематический провал на фрагментированных данных*

На раздробленном керне, в отличие от монолитных образцов, YOLO демонстрирует уже крайне низкую производительность, достигая итогового значения IoU лишь около 0,66. Более того, сам процесс обучения остается заметно нестабильным: метрика показывает сильные случайные колебания, особенно в

первые 50 эпох. Вероятно, это связано с рядом фундаментальных ограничений архитектуры YOLO при решении задач попиксельной классификации сложных структур:

#### *Потеря пространственной информации*

Архитектура YOLO включает глубокий энкодер, который последовательно уменьшает пространственное разрешение карт признаков для извлечения семантической информации. Если в случае крупного объекта это не становится критичной проблемой, то мелкие фрагменты ядра на глубоких слоях сети могут просто «исчезать» или сливаться с фоном, из-за чего их дальнейшая сегментация становится невозможной.

#### *Грубость генерации масок*

В отличие от U-Net, в которой симметричный декодер шаг за шагом восстанавливает карту сегментации до исходного разрешения, в YOLO-подобных архитектурах механизм генерации масок часто остается вторичным по отношению к детекции и работает с картами признаков пониженного разрешения. В результате границы оказываются «размытыми» и огрубленными, а несколько соседних фрагментов могут объединяться в одно «пятно», что резко снижает метрику IoU, чувствительную к точности оконтуривания.

#### *Парадигмальный конфликт*

YOLO опирается на представление сцены через отдельные объекты и ограничивающие их рамки. В случае раздробленного ядра это создает для модели принципиальную неоднозначность: воспринимать ли всю совокупность фрагментов как один объект или как набор множества мелких объектов. Именно эта неопределенность осложняет формирование корректного представления о сцене, что, в итоге, приводит к систематическим ошибкам.

Полученные результаты достаточно ясно показывают, что архитектура YOLO, при всех ее преимуществах в скорости и эффективности при решении задач детекции, плохо подходит для точной семантической сегментации сложных мелкоструктурированных объектов, к числу которых относятся раздробленные

образцы керна. Наблюдаемый двадцатипятипроцентный разрыв в итоговом качестве по сравнению с монолитными образцами нельзя объяснить случайными колебаниями - скорее, он отражает собственные архитектурные ограничения модели.

#### **2.2.4. Выводы о влиянии раздробленности**

Проведенное в данном подразделе исследование влияния раздробленности керна на качество сегментации позволяет сформулировать несколько ключевых выводов, которые далее служат основой для разработки гибридной архитектуры далее в работе:

1. Подтверждена уязвимость базовой U-Net: проведенные эксперименты показали, что классическая архитектура U-Net, несмотря на в целом хорошие результаты, при работе с сильно фрагментированными образцами керна заметно уступает по стабильности и точности. Это позволяет предположить, что стандартные пропускные связи не всегда достаточно эффективно передают разномасштабную информацию, необходимую для одновременной сегментации крупных и мелких объектов.
2. Выявлено эффективное архитектурное решение: сравнительный анализ показал, что архитектура U-Net++ превосходит стандартную U-Net по устойчивости к проблеме фрагментации. То, что разрыв в качестве сегментации между монолитными и раздробленными образцами остается минимальным, напрямую связано с ее ключевой особенностью - вложенными и плотными пропускными связями.
3. Сформирована стратегия модификации: полученные результаты задают достаточно понятное направление для улучшения базовой U-Net. Вместо обучения отдельных моделей для разных типов керна, что в практическом отношении выглядит не самым удобным решением, логичнее модифицировать саму архитектуру, встроив в нее элементы, уже доказавшие свою эффективность.

Таким образом, на основе проведенного анализа принимается решение: при разработке гибридной нейронной сети в разделе 2.3 в качестве одного из ключевых усовершенствований будет внедрен механизм вложенных плотных пропускных связей, аналогичный используемому в U-Net++. Этот шаг направлен на целенаправленное устранение выявленной слабости базовой U-Net и повышение робастности итоговой модели при работе с геологическими образцами любой степени раздробленности.

### **2.3. Создание гибридной архитектуры для повышения эффективности сегментации на образцах керна**

В предыдущих разделах было проведено сравнение различных архитектур нейронных сетей, по результатам которого для решения задачи сегментации образцов керна была выбрана U-Net. Данная архитектура продемонстрировала наиболее сбалансированное соотношение между качеством сегментации и вычислительной эффективностью, показав результат Val Dice 0,910 и Val IoU 0,862 при времени обработки одного изображения около 0,15 секунды.

Хотя U-Net давно воспринимается как одна из основных архитектур для семантической сегментации, применительно к нашей задаче ее возможностей все же оказалось недостаточно для полноценного использования в промышленных условиях. Основные ограничения связаны с недостаточной точностью при работе со сложными, сильно раздробленными образцами керна, а также с необходимостью дополнительно ускорить обработку при больших потоках данных.

Поэтому было решено разработать новую гибридную архитектуру, в которой объединены наиболее удачные подходы из разных семейств нейронных сетей и которая специально адаптирована под геологические изображения.

#### **2.3.1. Уменьшение числа параметров и ускорение вычислений**

Одной из важных задач является сокращение вычислительных затрат при повышении общей эффективности модели. Этот эффект был достигнут за счет

замены стандартных 2D-сверток на глубинно-разделяемые. В результате операция свёртки делится на два этапа [80-82]:

1. Depthwise-свёртка - к каждому входному каналу применяется отдельный независимый фильтр, что позволяет выявлять пространственные зависимости внутри каждого канала по отдельности.
2. Pointwise-свёртка - затем используется свертка размером  $1 \times 1$ , объединяющая информацию между каналами.

Общее число параметров в таком блоке сокращается с

$$k^2 \cdot M \cdot N \text{ до } k^2 \cdot M + M \cdot N, \quad (2.6)$$

где  $k$  – размер ядра свёртки под одной оси,  $M$  – число входных каналов,  $N$  – число выходных каналов,  $k^2 \cdot M$  – параметры глубинно-разделяемой свертки (по одному фильтру на входной канал),  $M \cdot N$  – параметры поточечной свертки ( $1 \times 1$ ).

Практически использование такого подхода приводит к уменьшению количества операций с плавающей точкой (FLOPS) в среднем в 3–4 раза, при всём этом заметного ухудшения метрик сегментации не наблюдается.

Для участков с высокой плотностью признаков (то есть на нижних уровнях энкодера) сохраняются традиционные  $3 \times 3$  свёртки, тогда как на более глубоких слоях используются глубинно-разделимые. Это дополнительно снижает вычислительные затраты без потери выразительности модели. Такой прием позволил сократить среднее время инференса на изображение при сохранении значений метрик Dice и IoU.

### 2.3.2. Добавление промежуточных связей между слоями

В классической архитектуре U-Net используются прямые пропускные связи, которые связывают слои энкодера и декодера на одном уровне. Чтобы более полно использовать признаки разных уровней абстракции, а также улучшить передачу контекстной информации, в гибридную архитектуру была встроена концепция, заимствованная из U-Net++. Была сформирована сетка промежуточных узлов, в

которой признаки с разных уровней энкодера последовательно агрегируются перед объединением в декодере.

В математическом виде данная концепция упрощенно выглядит следующим образом [79, 84]:

Пусть  $d_i$  – карта признаков декодера на уровне  $i$ .

Прямые пропускные связи:

$$d_i = H(\text{concat}(e_i, U(d_{i+1}))), \quad (2.7)$$

где  $e_i$  – карта признаков энкодера на уровне  $i$ ,  $U(x)$  – повышение пространственного разрешения,  $H(x)$  – сверточный блок,  $\text{concat}$  – конкатенация.

Вложенные плотные связи:

$$d_i = H(\text{concat}(e_i^0, e_i^1, \dots, e_i^m, U(d_{i+1}))), \quad (2.8)$$

где  $e_i^0, e_i^1, \dots, e_i^m$  – промежуточно агрегированные карты признаков на данном уровне.

Описанный подход позволил: уменьшить семантический разрыв между картами признаков, повысить стабильность обучения и улучшить распознавание границ мелких и сложных объектов, что особенно важно при анализе пород со сложной морфологией.

### 2.3.3. Снижение риска «забывания» ранних признаков и улучшение сходимости

Глубокие нейронные сети подвержены проблеме затухания градиента: при обратном распространении ошибки градиенты на ранних слоях становятся исчезающе малыми, из-за чего обучение заметно усложняется. Для решения этой проблемы стандартные сверточные блоки были заменены на остаточные блоки, идея которых была предложена в архитектуре ResNet [83, 92].

$$Y = \text{ReLU}(x + F(x)), \quad (2.9)$$

$$F(x) = \text{Conv}_2(\text{ReLU}(\text{Conv}_1(x))), \quad (2.10)$$

где  $x$  – входная карта признаков блока,  $Y$  – выходная карта признаков блока,  $F(x)$  – остаточное преобразование, ReLU – функция активации, Conv<sub>1</sub>, Conv<sub>2</sub> – сверточные операции с разными параметрами.

В таком блоке выход определяется как сумма входа  $x$  и результата нелинейных преобразований  $F(x)$ , примененных к этому входу. Благодаря этому возникает прямой путь для распространения градиента через остаточную ветвь, что облегчает обучение, делает процесс сходимости более устойчивым и позволяет сети эффективнее передавать признаки с ранних слоев на более глубокие, не теряя их.

Важным следствием является, что данный прием позволил увеличить глубину гибридной архитектуры до 8 уровней вместо 5, не увеличивая при этом число эпох и не ухудшая сходимость.

#### 2.3.4. Увеличение эффективности работы на сильно раздробленных образцах керна

Образцы керна часто содержат множество мелких фрагментов, микроскопических трещин и неоднородных текстур, поэтому от нейронной сети требуется более внимательная работа с деталями. Чтобы модель могла «фокусироваться» на наиболее информативных областях изображения, в архитектуру были добавлены блоки внимания [91].

Блоки внимания вычисляют специальную карту весов (карта внимания), которая усиливает значения признаков в «важных» областях и ослабляет их в фоне. В результате признаки в значимых зонах становятся более выраженными. Для сегментации керна это особенно полезно, поскольку сеть начинает точнее выделять тонкие границы и характерные структуры керна.

$$\psi = \sigma(\text{BN}(\text{Conv}(\text{ReLU}(W_g \cdot G + W_x \cdot X))))), \quad (2.11)$$

где  $\psi$  – карта внимания, ReLU – функция активации, Conv – сверточная операция,  $G$  – гейт-сигнал с более глубокого уровня сети,  $X$  – низкоуровневые признаки с

энкодера,  $W_g$ ,  $W_x$  – обучаемые параметры, BN – пакетная нормализация,  $\sigma$  – сигмоида. После этого выход вычисляется как:

$$X' = X \odot \psi, \quad (2.12)$$

где  $X'$  – выход блока внимания,  $\odot$  – поэлементное умножение. В результате значения признаков в «важных» областях усиливаются. Для сегментации керна это чрезвычайно полезно, так как сеть «фокусируется» на тонких границах и структурах керна, что особенно критично для раздробленных образцов.

В результате, использование блоков внимания оказало следующее влияние на работу модели: увеличение значения метрики Recall; снижение шумовых «артефактов»; рост общего качества сегментации для фрагментированных образцов керна.

### **2.3.5. Разработка алгоритма «онлайн» аугментации**

Помимо архитектурных улучшений, важную роль в обучении глубоких нейронных сетей играют качество и разнообразие обучающих данных. Сбор и ручная разметка большого датасета геологических изображений – это крайне трудоемкий и дорогостоящий процесс, требующий участия высококвалифицированных экспертов-геологов. Таким образом, когда объем исходных данных ограничен первоочередной задачей является максимально полное извлечение полезной информации из уже имеющейся выборки.

Стандартным решением в таком случае является «оффлайн» аугментация - предварительное создание расширенного набора данных за счет применения к исходным изображениям различных трансформаций, например отражений и поворотов. Однако у такого подхода есть два существенных недостатка:

- значительные требования к хранению данных: аугментированный датасет может занимать в несколько раз больше дискового пространства, чем исходный, что становится проблемой при работе с изображениями высокого разрешения;

- ограниченная вариативность: на каждой эпохе обучения модель видит один и тот же, пусть и расширенный, набор статических изображений. В результате разнообразие данных остается ограниченным, и это может приводить к переобучению на отдельные варианты трансформаций.

Для того чтобы устранить указанные ограничения и сделать гибридную модель более устойчивой, был разработан и внедрен алгоритм «онлайн» аугментации, работающий непосредственно в ходе обучения. При таком подходе на каждой эпохе формируются новые варианты изображений, за счет чего обучающая выборка постоянно обновляется, но объем данных на диске при этом не увеличивается.

Принцип работы алгоритма (приложение А) заключается в том, что при формировании каждого батча данных загрузчик обращается к исходному изображению и его маске, после чего применяет к ним случайную комбинацию преобразований. Благодаря механизму рандомизации, даже одно и то же исходное изображение на разных эпохах будет представлено в сети по-разному, что значительно повышает обобщающую способность модели.

В рамках алгоритма используется двухступенчатый механизм рандомизации:

- каждая из возможных трансформаций активируется с заданной вероятностью (например, 50%), что обеспечивает разнообразие комбинаций аугментаций;
- для каждого применяемого преобразования его параметры также выбираются случайным образом из заданного диапазона.

Использовались следующие виды трансформаций:

- геометрические: горизонтальное и вертикальное отражение, случайное кадрирование (обрезание);
- фотометрические: случайное изменение яркости и контрастности (например, в диапазоне  $\pm 20\%$ ), добавление гауссова шума.

Тщательная настройка вероятностей и диапазонов параметров позволила сохранить фотореалистичность изображений, при этом значительно расширив вариативность обучающей выборки.

### 2.3.6. Настройка гиперпараметров и оценка качества работы гибридной архитектуры

Разработка новой архитектуры сама по себе еще не решает задачу. Не менее важным этапом остается обучение модели, поскольку именно от него в значительной степени зависят и итоговая производительность, и способность модели к обобщению. Этот процесс задается набором внешних параметров, которые не обновляются в ходе обратного распространения ошибки, - гиперпараметров. Их подбор требует довольно хорошего понимания того, как они влияют на динамику обучения. В данном разделе рассматривается методика настройки ключевых гиперпараметров для гибридной U-Net, а также приводятся анализ и интерпретация результатов, полученных в эксперименте по сравнению эффективности существующих архитектур с новой гибридной моделью.

Если говорить в общем, обучение нейронной сети сводится к задаче минимизации функции потерь. Насколько успешно будет идти этот процесс, напрямую определяется выбором оптимизатора, скорости обучения и методов регуляризации.

#### *1. Оптимизатор и функция потерь*

Оптимизатор – это алгоритм, который шаг за шагом обновляет веса нейронной сети на основе вычисленных градиентов функции потерь. Для обучения гибридной модели вместо классического стохастического градиентного спуска был выбран оптимизатор Adam за счет его доказанной эффективности, быстрой сходимости и устойчивости к выбору начальных гиперпараметров по сравнению со стохастическим градиентным спуском.

Adam относится к адаптивным алгоритмам и вычисляет индивидуальные скорости обучения для каждого параметра. В его основе работы находятся две ключевые идеи:

- инерция – накапливает экспоненциально затухающее скользящее среднее прошлых градиентов (первый момент), что позволяет сгладить траекторию движения в пространстве весов и ускорить сходимость. Этот аспект

контролируется гиперпараметром  $\beta_1$ , который в наших экспериментах был установлен на стандартное значение 0,9;

- масштабирование градиентов – накапливает экспоненциально затухающее скользящее среднее квадратов прошлых градиентов (второй момент), что позволяет ослаблять обновления для параметров с большими градиентами и усиливать их для параметров с малыми, что, в свою очередь, нормализует градиент и помогает избежать «застревания» на плато. Масштабирование градиентов контролируется гиперпараметром  $\beta_2$ , который был принят равным 0,999.

Функции потерь – комбинация бинарной кросс-энтропии и функции потерь на основе коэффициента Дайса:

$$\mathcal{L}_{BCE} = -\frac{1}{H \cdot W} \sum_{i=1}^H \sum_{j=1}^W [y_{ij} \cdot \ln p_{ij} + (1 - y_{ij}) \cdot \ln(1 - p_{ij})], \quad (2.13)$$

где  $\mathcal{L}_{BCE}$  – функция потерь «бинарной кросс-энтропии»,  $H$  – высота изображения,  $W$  – ширина изображения,  $i, j$  – индексы пикселей,  $y_{ij} \in \{0,1\}$  – истинная метка пикселя,  $p_{ij} \in (0,1)$  – предсказанная моделью вероятность принадлежности пикселя  $(i, j)$  к породе.

$$\mathcal{L}_{Dice} = 1 - \frac{2 \cdot \sum y_{ij} \cdot p_{ij} + \varepsilon}{\sum y_{ij} + \sum p_{ij} + \varepsilon}, \quad (2.14)$$

где  $\mathcal{L}_{Dice}$  – функция потерь на основе коэффициента Дайса,  $\varepsilon$  – малое число для численной устойчивости.

## 2. Скорость обучения и ее адаптация

Скорость обучения определяет величину шага при обновлении весов и является одним из важнейших гиперпараметров, так как, например, слишком высокая скорость обучения может привести к «перепрыгиванию» через минимум функции потерь и расхождению модели, в то время как слишком низкая – к недопустимо медленной сходимости или «застреванию» в локальном минимуме.

Для выбора оптимального начального значения был выполнен краткий поиск по сетке  $\{1 \cdot 10^{-3}, 5 \cdot 10^{-4}, 1 \cdot 10^{-4}\}$ . На старте обучения наилучшим показателем

скорость обучения оказался, равный  $1 \cdot 10^{-4}$ : при таком значении функция потерь в первых эпохах снижалась наиболее ровно и достаточно быстро, без заметных осцилляций, что указывает на хорошо подобранный шаг градиентного спуска.

При этом фиксированная скорость обучения не остается одинаково подходящей на всем протяжении обучения. Для более тонкой подстройки модели на поздних этапах был использован адаптивный планировщик `ReduceLROnPlateau`. Этот механизм отслеживает значение метрики качества, в нашем случае `Dice`, и автоматически уменьшает скорость обучения, в нашем случае в 2 раза, если метрика не улучшается в течение заданного числа эпох (3 эпохи). Такой подход позволяет модели в начале обучения двигаться более крупными шагами, а ближе к завершению переходить к более аккуратной настройке, что в итоге положительно влияет на качество.

### *3. Размер батча*

Размер батча определяет, сколько обучающих примеров используется за один шаг обновления весов. Этот гиперпараметр связан сразу с несколькими факторами, между которыми, по сути, приходится искать компромисс:

- точность оценки градиента: большие батчи дают более точную оценку градиента по всей выборке, что делает обучение более стабильным;
- вычислительные ресурсы: размер батча напрямую ограничивается объемом видеопамяти;
- обобщающая способность: меньший размер батча вносит дополнительный шум в оценку градиента, и в ряде случаев это работает как своеобразная форма регуляризации. За счет этого модели бывает проще выйти из острых локальных минимумов и прийти к более «плоским» решениям, которые, как правило, лучше переносятся на новые данные.

Экспериментально было установлено, что размер батча, равный 10, является оптимальным для нашей задачи и используемой аппаратной конфигурации. При таком значении обучение идет достаточно стабильно, без проблем с нехваткой

памяти, и в то же время сохраняется тот уровень стохастичности, который полезен для нормального, не слишком «жесткого» обучения модели.

#### *4. Методы регуляризации для борьбы с переобучением*

Переобучение – это ситуация, при которой модель слишком точно запоминает обучающую выборку, но при этом хуже справляется с обобщением на новых, ранее не встречавшихся данных. Для снижения риска такого поведения был использован комплекс методов регуляризации:

- L2-регуляризация;

К функции потерь добавляется штраф, пропорциональный сумме квадратов весов модели. Это заставляет оптимизатор предпочитать модели с меньшими весами, что делает их менее сложными и более устойчивыми к шуму в данных. В нашем исследовании был использован коэффициент затухания весов, равный  $1 \cdot 10^{-5}$ .

- dropout;

На этапе обучения случайным образом «отключается» (обнуляется) часть нейронов со своих выходов. Это мешает нейронам формировать сложные коадаптации друг с другом и заставляет их учиться более робастным и независимым признакам. Dropout с вероятностью  $p=0.1$  был применен в bottleneck архитектуры, где признаки наиболее семантически насыщены.

- ранняя остановка.

Процесс обучения останавливается, как только метрика качества на валидационной выборке перестает улучшаться в течение заданного числа эпох (в рамках работы принято значение в 5 эпох). Параллельно с этим сохраняется та версия модели, которая показала наилучший результат на валидации. Это не только предотвращает переобучение, но и экономит вычислительные ресурсы, избавляя от необходимости проводить избыточные эпохи обучения.

#### *Оценка качества и анализ результатов*

Ключевые результаты полученной гибридной сети в сравнении с оригинальной U-Net и U-Net++ показаны в таблице 2.9.

Таблица 2.9 – Результаты работы гибридной сети

Модель	Dice (train)	IoU (train)	Dice (test)	IoU (test)	Время инференса, сек	GPU RAM, ГБ
Оригинальный U-Net	0,903	0,872	0,910	0,862	0,15	4,0
U-Net++	0,916	0,882	0,920	0,870	0,18	6,5
Гибридная архитектура	0,961	0,952	0,967	0,936	0,10	7,0

Анализ полученных результатов позволяет сделать следующие выводы:

- по сравнению с базовой U-Net гибридная архитектура показала рост качества сегментации: Dice увеличился с 0,910 до 0,967, а IoU - с 0,862 до 0,936, что соответствует относительному приросту на 6% и 8% соответственно. Этот прирост связан с совокупным действием всех внедренных улучшений: остаточные блоки сделали сеть более глубокой и выразительной, вложенные плотные пропускные связи улучшили передачу контекстной информации, нужной для точного оконтуривания, а блоки внимания помогли модели лучше выделять сложные границы и мелкие фрагменты керна. Пример работы гибридной модели показан на рисунке 2.7;



Рисунок 2.7 – Пример работы разработанной гибридной сети (синим выделены контуры, красным – сами образцы пород)

- несмотря на усложнение архитектуры, среднее время обработки одного изображения сократилось на 33% - с 0,15 с до 0,10 с. Такой результат был получен в первую очередь за счет замены стандартных сверток на более вычислительно эффективные – глубинно-разделяемые свертки;
- рост потребления видеопамати до 7,0 ГБ является ожидаемой платой за более сложную архитектуру с большим числом хранимых карт признаков, в первую очередь из-за вложенных плотных пропускных связей. При этом данное значение все же остается в пределах возможностей современных графических ускорителей среднего класса, что подтверждает сбалансированность модели;
- об отсутствии переобучения и высокой обобщающей способности разработанной модели можно судить по плавной кривой обучения и высоким и близким значениям метрик на обучающей (0,961) и валидационной (0,967) выборках.

Комплексный подход, сочетающий инновационные архитектурные решения и тщательную настройку процесса обучения, позволил создать гибридную модель, которая не просто улучшает базовую, а дает качественный скачок в решении специфической задачи сегментации образцов керна.

#### **2.4. Выводы по второй главе**

Во второй главе настоящей работы проведено комплексное исследование, в рамках которого была разработана и проверена новая гибридная архитектура нейронной сети для задачи семантической сегментации макрофотографий образцов керна. В итоге, были сформулированы следующие выводы:

1. В результате сравнительного анализа пяти архитектур (U-Net, U-Net++, SegNet, YOLOv8-seg, YOLOv11-seg) была определена наиболее оптимальная базовая модель. Оригинальная архитектура U-Net продемонстрировала наиболее оптимальное сочетание высокой точности сегментации (Val Dice 0,910, Val IoU 0,862), умеренного потребления вычислительных ресурсов (4,0

ГБ памяти видеопроцессора) и скорости обработки (0,15 с). Всё перечисленное делает ее наиболее подходящей базой для дальнейших модификаций.

2. Качество и разнообразие обучающих данных были определены как один из главных факторов. Для решения проблемы ограниченного объема исходных данных, полученных в результате трудоемкой ручной разметки экспертами-геологами, был разработан и внедрен алгоритм «онлайн» аугментации. В отличие от стандартных «оффлайн» методов, предложенный подход генерирует уникальные трансформации изображений в процессе обучения, что обеспечивает максимальное разнообразие данных без увеличения требований к дисковому пространству и заметно повышает обобщающую способность и робастность итоговой модели.
3. Был выполнен анализ влияния степени раздробленности керна на качество сегментации, в ходе которого выявлена ключевая уязвимость базовой архитектуры U-Net. Установлено, что производительность стандартной U-Net снижается при работе с сильно фрагментированными образцами. В то же время было экспериментально доказано, что архитектура U-Net++ показывает более хорошие результаты при работе с раздробленными породами благодаря использованию вложенных плотных пропускных связей. Этот вывод стал прямым научным обоснованием выбора одного из ключевых направлений модификации базовой U-Net.
4. Для решения выявленных проблем оригинальной U-Net в разрезе задачи сегментации фрагментированных образцов пород была разработана и протестирована новая гибридная архитектура, в которую были интегрированы следующие технологии компьютерного зрения:
  - вложенные плотные пропускные связи для повышения робастности при работе с фрагментированными образцами;
  - глубинно-разделяемые свертки для снижения вычислительной сложности и уменьшения времени обработки на 33% (с 0,15 с до 0,10 с);

- остаточные блоки для устранения проблемы затухания градиента, что позволило увеличить глубину сети и улучшить сходимость;
  - блоки внимания, которые позволяют модели акцентировать внимание на наиболее важных признаках, что повысило точность оконтуривания для сильно фрагментированных образцов керна, а также позволило увеличить метрику Recall.
5. Разработанная гибридная архитектура оказалась более эффективной чем все остальные сети, участвовавшие в анализе. Итоговые метрики качества на тестовой выборке достигли значений  $Dice = 0,967$  и  $Val IoU = 0,936$ , что в относительном выражении на 6% и 8% соответственно выше, чем у исходной U-Net. При этом время обработки изображений также удалось сократить, что подтверждает высокую эффективность предложенных модификаций.

В рамках настоящей главы была последовательно разработана и протестирована новая гибридная архитектура, адаптированная к специфике задач сегментации геологических образцов. Созданная модель сочетает высокую точность, в том числе при работе со сложными фрагментированными образцами, и вычислительную эффективность. Всё вышперечисленное подтверждает ее практическую значимость для внедрения в промышленные системы автоматизированного анализа керна.

### **Глава 3. Разработка алгоритма оценки нефтенасыщенности образцов керна на основе УФ-свечения**

Нефтенасыщенность на макрофотографиях керна традиционно оценивается визуально: специалист сопоставляет изображения в видимом и УФ диапазонах, выделяет интервалы свечения и фиксирует его тип, характер и интенсивность. Такой подход трудоёмок, зависит от исполнителя и плохо воспроизводится при работе с большими объёмами материалов. В настоящей главе решается задача автоматизированного определения и классификации нефтенасыщенных интервалов по признакам УФ-свечения. Для этого формируется обучающий датасет и обучается нейросетевая модель, которая предсказывает тип, характер и интенсивность свечения и тем самым поддерживает принятие решения о наличии нефти на заданном интервале глубин. Одним из ключевых решений является совместное использование изображений в видимом и УФ диапазонах.

#### **3.1. Связь УФ-свечения керна с нефтенасыщенностью**

Съёмка керна в УФ диапазоне на практике довольно давно используется как быстрый способ индикации наличия углеводородов в поровом пространстве. Это связано с тем, что часть компонентов нефти способна флуоресцировать, поэтому нефтенасыщенные зоны на таких изображениях обычно выглядят как локальные светящиеся участки. За счет этого можно достаточно оперативно выделять потенциально нефтенасыщенные интервалы, в том числе тонкие прослой и участки с неоднородным насыщением. Кроме того, анализ УФ свечения помогает более обоснованно выбирать точки отбора для дорогостоящих лабораторных исследований.

Кроме того, когда лабораторные данные отсутствуют или представлены не в полном объеме, съёмка в УФ диапазоне, по сути, остается одним из немногих источников информации о распределении флюида. Поэтому качественная и объективная обработка таких изображений делает цифровой архив керна более

ценным с практической точки зрения и снижает риск того, что нефтенасыщенные зоны будут пропущены уже на ранних этапах интерпретации.

При этом съёмка в видимом диапазоне дает в основном другую информацию. На ней фиксируются прежде всего литологические признаки (то есть цвет, текстура и структура породы), но сама по себе она не позволяет судить о наличии флюида. УФ-изображение, наоборот, показывает распределение флуоресценции и тем самым дополняет данные видимого диапазона информацией о насыщении.

Но на практике важно не только заметить свечение, а еще и правильно понять его природу. Дело в том, что оно может быть связано не только с нефтью, но и, например, с минеральным составом, карбонатизацией, остатками бурового раствора (фильтратом), а также поверхностными или биогенными отложениями. Поэтому для выделения нефтенасыщенных интервалов нужен совместный анализ обоих изображений. Снимок в видимом диапазоне дает контекст породы и литологии, а снимок в УФ диапазоне позволяет увидеть, где именно локализовано свечение и насколько оно выражено. Разработанный в главе подход автоматизирует выделение зон флуоресценции и их классификацию, что снижает вероятность неверной трактовки причин свечения.

Если рассматривать задачу с точки зрения количественного сопряжения с петрофизикой, то важен не только сам факт наличия свечения, но и его конкретные измеримые характеристики. Предложенный в главе подход формирует цифровое представление зоны свечения, в которое входят маска флуоресценции, интервал свечения (координаты по керновой оси), а также оценка типа, характера и интенсивности свечения. В дальнейшем эти величины могут использоваться как параметры для калибровки по лабораторным измерениям нефтенасыщенности и пористости. Также они могут применяться для построения зависимостей признаков свечения от показателей насыщения в рамках более широкого исследования.

Таким образом, автоматизированное выявление и классификация УФ-свечения в данной работе рассматриваются не просто как вспомогательный способ визуализации. По сути, это один из важных элементов цифрового кернового

анализа, напрямую связанный с задачей установления наличия нефти на интервале. Дальнейшее использование полученных результатов, то есть масок и атрибутов свечения (тип, характер, интенсивность), дает возможность формализованно сопоставлять их с петрофизическими данными и в целом делает цифровой архив керна более ценным для повторной интерпретации.

### 3.2. Формализация признаков УФ-свечения

В настоящей работе задача определения нефтенасыщенности формулируется как классификация УФ-свечения по трем признакам, принятым в производственных описаниях керна. Такой выбор обеспечивает совместимость результатов алгоритма с существующими отчетными формами, пример такой отчетной формы показан на рисунке 3.1, и позволяет встраивать модель в действующие процессы интерпретации.

№	Данные по керну				Пласт	Свечение				
	Кровля, м	Подшва, м	Проходка, м	Вынос, %		Глубина от начала керна, 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

Рисунок 3.1 – Пример отчета по анализу образцов керна

Тип свечения рассматривается как основной признак наличия нефти на интервале. На уровне данных он задаётся категориальной меткой из ограниченного множества классов, соответствующих принятой в производственных отчётах номенклатуре: «Углеводород» (УВ), «Углеводород совместно с карбонатом» (УВ+К), «Карбонат» (К), «Карбонат совместно с углеводородом» (К+УВ), «Фильтрат бурового раствора» (ФБР), «Свечение обусловлено минеральным

составом» (М). Для задач оперативной интерпретации ключевым является выделение классов, указывающих на присутствие углеводов (прежде всего «Углеводород» и смешанные варианты), поскольку они служат основанием для выбора интервалов на детальные исследования и уточнение петрофизических параметров.

Интенсивность характеризует выраженность флуоресценции и задаётся шкалой: «Низкая», «Средняя», «Высокая». Несмотря на условность границ между уровнями, данный параметр практически значим, поскольку помогает ранжировать интервалы по степени проявления нефти и обеспечивает сопоставимость между партиями данных при повторной интерпретации.

Характер свечения описывает пространственный рисунок распределения флуоресценции и фиксируется в отчётах в виде условных кодов. В используемой номенклатуре приняты следующие значения: «Однородный» (О), «Неоднородный» (НО), «Равномерный» (РМ), «Неравномерный» (НР), «Слоистый» (С), «Переслаивание с ненасыщенными слоями» (ПНС), «Переслаивание с карбонатизированными слоями» (ПКС), «Пятнистый» (П), «Линзовидный» (Л), «Текстурный (оползневой, биотурбационный, эрозионный)» (Т), «Трещинный» (ТР), «Редкий» (Р). Данный признак включает наибольшую долю экспертной интерпретации и допускает неоднозначные переходные случаи (в том числе указание нескольких кодов для одного интервала). Поэтому «характер» рассматривается как вспомогательный атрибут для описания геометрии и распределения свечения, а оценка качества по этому выходу интерпретируется с учётом межэкспертной вариативности и дисбаланса классов.

### **3.3. Формирование датасета**

Для обучения и валидации модели необходим набор данных, в котором каждой паре изображений «видимый + УФ диапазон» сопоставлены значения атрибутов свечения и метаданные интервала. В рамках работы разработан автоматизированный конвейер подготовки данных, который превращает снимки

керна в структурированный датасет и тем самым сокращает долю ручной работы. Основные шаги работы конвейера представлены в таблице 3.1.

Таблица 3.1 – Конвейер формирования датасета

№	Шаг конвейера	Краткое описание	Инструменты
1	Сегментация образцов изображений в видимом и УФ диапазонах	Пара изображений керна («видимый + УФ диапазон») проходит сегментацию: гибридная архитектура на основе U-Net, разработанная в главе 2, выделяет область породы и исключает фон. По полученному контуру формируется сегментированное УФ-изображение	PyTorch, гибридная U-Net, .NET
2	OCR извлечение метаданных	Из изображения в видимом диапазоне автоматически выделяются области маркировок. Распознавание выполняется EasyOCR с последующим постпроцессингом (фильтрация, приведение форматов, проверка согласованности интервалов) для извлечения глубины, номера керна и условных обозначений.	EasyOCR, OpenCV, .NET
3	Слияние с лабораторными Excel отчётами и выделение зон флуоресценции	Результаты OCR объединяются с производственными Excel-отчётами по ключам «номер керна + интервал глубин» (и при наличии – скважина/пласт/месторождение). Выполняются нормализация обозначений и контроль целостности (поиск пропусков, дубликатов и конфликтов). По данным отчетов нарезаются интервалы УФ свечения и сопоставляются с изображениями в видимом диапазоне.	.NET, Python
4	Экспорт	Экспорт готового датасета: сохранение пар изображений (видимое/УФ), масок флуоресценции для каждой пары, формирование <i>meta.csv</i> с целевыми метками и служебными полями, разбиение на обучающую и тестовую выборки.	Python

Технической основой конвейера выступает разработанная гибридная архитектура сегментации: она устойчиво выделяет область породы на изображениях в видимом диапазоне, а затем переносит контур на УФ-изображение, снижая влияние фоновых объектов и обеспечивая сопоставимость входных данных для классификатора.

Алгоритм обучения модели классификации нефтенасыщенности, включающий в себя конвейер подготовки данных, представлен на рисунке 3.2.

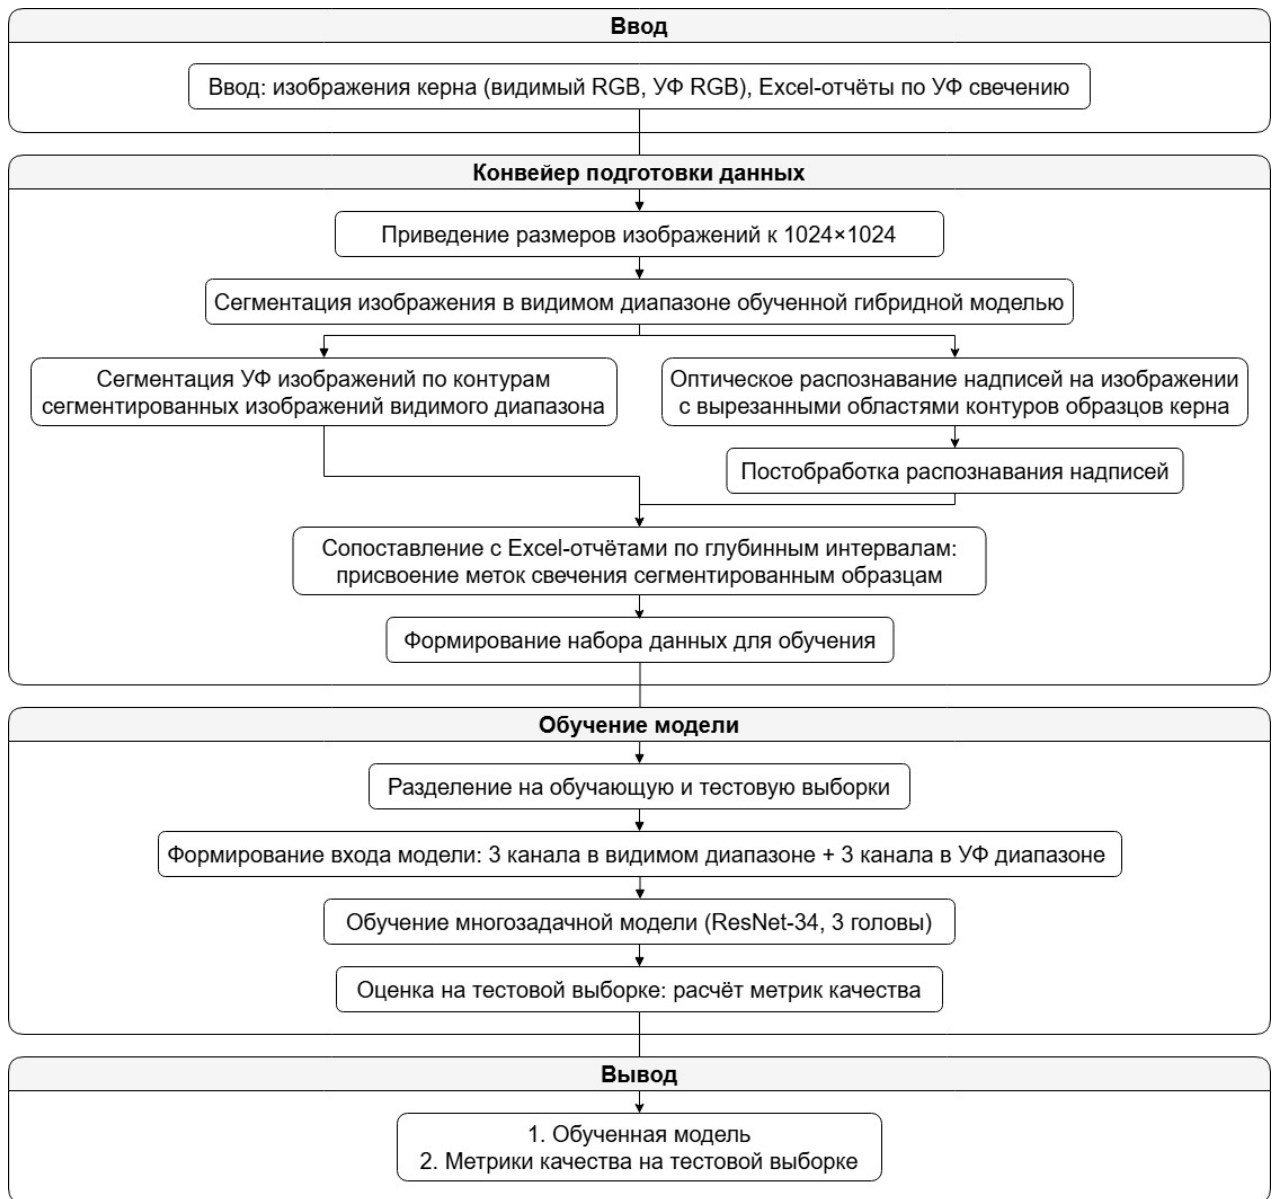


Рисунок 3.2 – Алгоритм обучения модели классификации нефтенасыщенности

Воспроизводимость результатов во многом обеспечивается за счет вариативности исходных материалов. В выборку вошли фотографии керна из нескольких месторождений, а исходные отчеты по свечению были подготовлены разными специалистами независимо друг от друга. За счет этого датасет можно считать более приближенным к реальным производственным условиям, а риск подстройки алгоритма под индивидуальный стиль описания или особенности

какого-то одного объекта становится ниже.

Отдельно стоит отметить и экономический эффект. Ручная разметка одного изображения керна - с выделением зон свечения и переносом метаданных из маркировок и отчетов - заняла бы 3 часа. При использовании автоматизированного конвейера, включающего гибридную сегментацию на основе U-Net, распознавание текста с помощью EasyOCR и объединение данных с отчетами Excel, время подготовки сократилось до 4 минут. При этом эксперт в среднем тратит еще 10-20 секунд на проверку одной маски и правильности меток. Такой режим, с одной стороны, сохраняет контроль качества, а с другой - заметно снижает нагрузку на специалиста.

#### *Организация и состав датасета*

Итоговый набор данных включает 467 фрагментов. Каждый из них соответствует отдельной зоне флуоресценции, для которой в отчете имеется запись с описанием образцов керна. Чтобы обеспечить корректный протокол валидации, данные были разделены на обучающую и тестовую части в соотношении 70% на 30% со стратификацией по признаку типа свечения. Перед подачей в классификатор каждая пара изображений - из видимого и УФ диапазонов - а также маски флуоресценции приводятся к единому размеру 1024×1024 пикселей и затем объединяются по каналам, образуя тензор формы 1024×1024×6. При этом первые три канала соответствуют съемке в видимом диапазоне, а вторые три - съемке в УФ диапазоне.

Метаданные для каждого объекта хранятся в файле meta.csv и содержат идентификатор, привязку к интервалу глубин и целевые метки классификации - тип, характер и интенсивность УФ-свечения.

Отдельно выполняется этап контроля качества разметки. Результаты сегментации зон флуоресценции проверяются экспертом либо в режиме выборочной ревизии, либо при полном просмотре, после чего при необходимости в них вносятся исправления. Для отметок глубин, полученных из отчетов, выполняются: нормализация условных обозначений, выявление противоречий

между источниками (например, при несовпадении интервалов глубин на маркировке и в отчете). В том случае, если подобные конфликты обнаруживаются, применяется правило приоритета: исходные производственные отчеты рассматриваются как первичный источник истины, тогда как значения, полученные с помощью OCR, используются как ключ для поиска соответствующей записи и как средство автоматической привязки к изображению.

Поскольку фотографии и отчёты поступают из разных объектов и готовятся разными специалистами, в данных неизбежно присутствует межэкспертная вариативность в трактовке свечения. В рамках предлагаемого подхода эта вариативность не устраняется искусственно, а учитывается как часть реальной постановки задачи. Конвейер обеспечивает единый формат представления, за счёт чего модель обучается на данных с естественным разбросом экспертных оценок и демонстрирует переносимость на новые поступления без переопределения целевых классов.

Итоговая структура датасета представлена на рисунке 3.3.




Рисунок 3.3 – Пример структуры датасета

#### *Допущения и ограничения*

Для корректного обучения предполагается, что для пары «видимый+ УФ диапазон» соблюдена геометрическая сопоставимость фрагмента (один и тот же интервал, одинаковое положение в секции), а параметры съёмки находятся в допустимых пределах (отсутствие сильных пересветов, достаточная резкость, корректный баланс белого для видимого диапазона).

### **3.4. Модель многозадачной классификации УФ-свечения**

Следующим этапом выполняется обучение нейросетевой модели, которая по

любой новой паре изображений (видимый и УФ диапазон) автоматически находит зоны флуоресценции и для каждой из них определяет три признака УФ-свечения, используемые в производственной интерпретации: тип свечения (как признак наличия нефти), его интенсивность и характер распределения.

### *Формирование батчей*

Загрузчик читает строки meta.csv (был описан ранее в подразделе 3.3), по идентификатору извлекает файлы images\_day/{id}\_day.png и images\_uv/{id}\_uv.png, преобразует их в тензоры  $1024 \times 1024 \times 3$  и конкатенирует по каналному измерению, формируя вход  $1024 \times 1024 \times 6$ . Причем каждому образцу соответствует несколько интервалов свечения, каждый со своей маской и meta.csv. Одним батчем считается пара изображения в видимом и УФ диапазоне для одного образца керна, файлы meta.csv и маски свечения для них.

### *Архитектура модели*

В качестве блока извлечения признаков выбрана ResNet-34 [83]. Для учёта двух спектральных модальностей модифицирован первый свёрточный слой: вместо трёх каналов он принимает шесть (RGB-видимый и RGB-УФ):

$$X = \text{concat}(I_{\text{day}}, I_{\text{uv}}) \in R^{H \cdot W \cdot 6}, \quad (3.1)$$

где  $I_{\text{day}}$  – RGB изображение в видимом диапазоне,  $I_{\text{uv}}$  – RGB изображение в УФ диапазоне, concat – объединение по каналному измерению,  $X$  – итоговый шестиканальный вход модели,  $H$  – высота изображения,  $W$  – ширина изображения,  $R^{H \cdot W \cdot 6}$  – пространство тензоров размера  $H \cdot W \cdot 6$ .

Чтобы сохранить преимущества предобучения на ImageNet, веса первых трёх каналов инициализируются предобученными значениями, а дополнительные три канала инициализируются методом Кайминга. После глобальной агрегации значений последовательности по среднему значению формируется вектор признаков, который подаётся на три независимые классификационные головы (используется функция Softmax) для решения многозадачной задачи [92-97]:

$$p_k = \frac{e^{z_k}}{\sum_{j=1}^K e^{z_j}}, \quad (3.2)$$

где  $p_k$  – оценка вероятности принадлежности к классу  $k$ ,  $z_k$  – выход модели до нормировки для класса  $k$ ,  $K$  – число классов.

Постановка задачи многомодальной классификации сводится к тому, что требуемые атрибуты свечения отражают разные аспекты одного и того же физического явления. Интенсивность определяется яркостью и площадью свечения на УФ-кадре, тип связан с природой источника свечения (углеводороды, карбонаты, фильтрат бурового раствора, минеральная люминесценция), а характер описывает пространственный рисунок распределения флуоресценции в пределах интервала. В таких условиях целесообразно одновременное извлечение согласованных признаков, зависящих одновременно от литологического контекста и распределения свечения. В связи с чем и используется подход обучения с совместным анализом для данных в видимом и УФ-диапазоне единой моделью. Совместный анализ реализован путем объединения RGB-каналов пары изображений в единый шестиканальный вход.

Общий блок извлечения признаков обучается на всей совокупности данных, а три независимые классификационные головы специализируются на определении типа, характера и интенсивности УФ свечения. Этот подход позволяет повысить воспроизводимость, так как разные атрибуты рассматриваются во взаимосвязи друг с другом. Например, тип свечения позволяет определять допустимые интервалы значений для интенсивности, а информация из видимого диапазона уменьшает число ложных срабатываний, связанных с неуглеводородной люминесценцией. В итоге модель формирует согласованный прогноз сразу по трем признакам для каждого интервала, и это затем напрямую используется при автоматизированном выделении нефтенасыщенных зон.

Функция потерь задаётся суммой трёх кросс-энтропий, каждая из которых соответствует своему выходу (тип/характер/интенсивность). Для повышения обобщающей способности применены мягкие аугментации (горизонтальные отражения, повороты, лёгкие фотометрические преобразования и случайные обрезания с последующим масштабированием), которые сохраняют спектральные

признаки УФ-свечения и не приводят к искажению целевых атрибутов.

Алгоритм классификации нефтенасыщенности включает в себя как подготовку данных, так и саму классификацию; алгоритм изображен на рисунке 3.4.

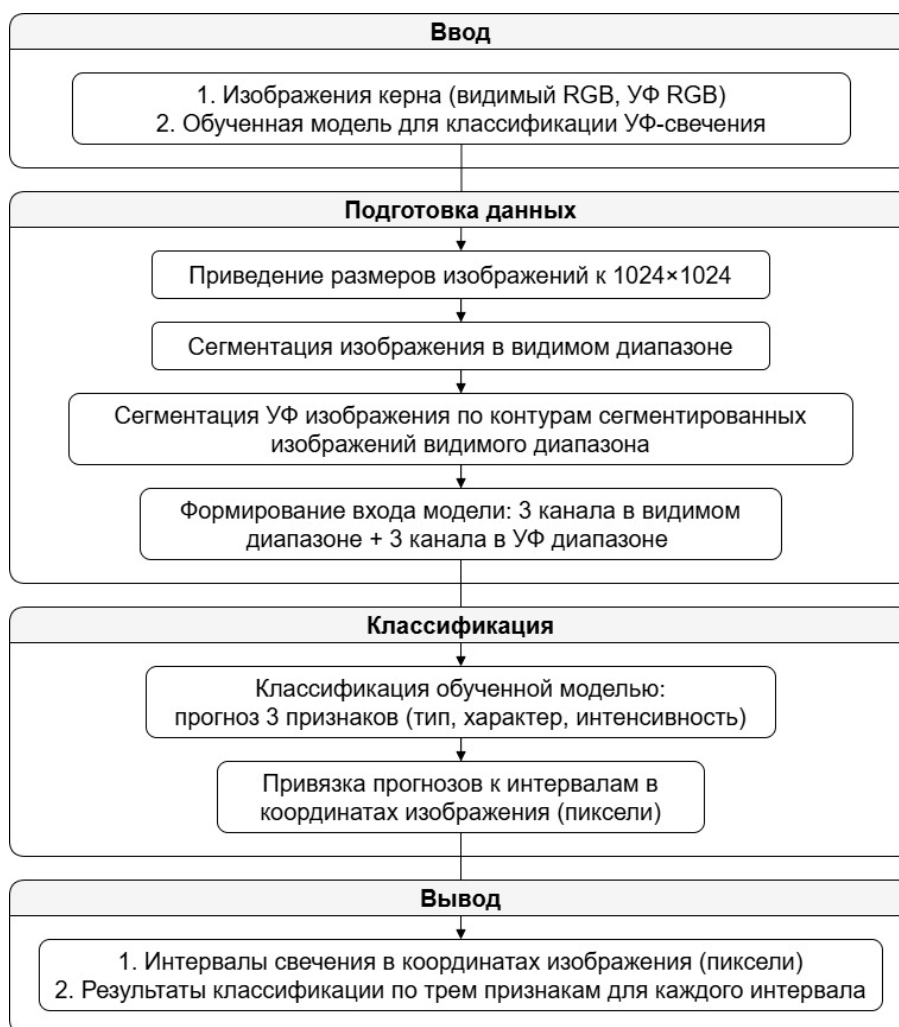


Рисунок 3.4 – Алгоритм оценки нефтенасыщенности образцов керна по изображениям в видимом и УФ диапазонах

Предложенный классификатор эффективен за счёт нескольких взаимодополняющих решений. Во-первых, используется шестиканальный ввод, в котором совмещены каналы изображения в видимом диапазоне (литологические и текстурные признаки) и каналы изображения в УФ диапазоне (пространственное распределение флуоресценции). Во-вторых, многозадачная постановка с общим блоком извлечения признаков и тремя головами позволяет совместно оптимизировать связанные признаки свечения и повышает стабильность обучения

на ограниченной выборке по сравнению с независимым обучением трёх отдельных моделей. В-третьих, использование маски ядра, рассчитанной сегментационной сетью, обеспечивает корректную локализацию зоны интереса в итоговой визуализации и поддерживает переход от субъективного описания интервалов к воспроизводимым цифровым признакам [98].

В результате алгоритм обеспечивает эффективный анализ фрагмента, сопоставимый по точности с экспертной оценкой для наиболее значимых атрибутов – типа и интенсивности свечения.

### **3.5. Проведение вычислительного эксперимента и оценка эффективности модели**

Для объективной проверки работоспособности и оценки обучения алгоритма сформированный набор данных разделён на две части – обучающую и тестовую в пропорции 70% на 30% со стратификацией по признаку типа свечения. Количество эпох для обучения составило 15. В качестве оптимизатора, как и для разработанной гибридной сети для сегментации, применялся оптимизатор семейства Adam – AdamW. Касательно подбора гиперпараметров: скорость обучения выставлена  $3 \cdot 10^{-4}$ , затухание весов принято равным  $1 \cdot 10^{-5}$ , размер батча - 32; валидация выполнялась после каждой эпохи.

Минимальное значение целевой функции на контрольной выборке составило 2,06 при train-loss равном 0,99. Полученные результаты свидетельствуют об умеренном расхождении между обучением и контролем качества; при этом явных признаков переобучения в рамках проведенного эксперимента не выявлено. Итоговые показатели значений метрик приведены в таблице 3.2.

Таблица 3.2 – Результаты тестирования модели классификации УФ-свечения

Выход модели	Accuracy	Macro-F1	Weighted-F1
Тип свечения	0,90	0,65	0,85
Интенсивность	0,80	0,63	0,79
Характер	0,60	0,46	0,70

$$Accuracy = \frac{1}{N} \cdot \sum_{n=1}^N I[\hat{y}_n = y_n], \quad (3.3)$$

где  $Accuracy$  – доля правильно классифицированных объектов,  $N$  – число объектов в наборе оценки,  $n$  – индекс объекта,  $y_n$  – истинный класс объекта  $n$ ,  $\hat{y}_n$  – предсказанный класс объекта  $n$ ,  $I[]$  – индикаторная функция (1 при совпадении классов, иначе – 0).

$$F1_{macro} = \frac{1}{K} \cdot \sum_{k=1}^K F1_k, \quad (3.4)$$

где  $F1_{macro}$  –  $F1$  с макро-усреднением,  $K$  – число классов,  $F1_k$  –  $F1$ -мера, рассчитанная отдельно для класса  $k$ .

$$F1_{weighted} = \sum_{k=1}^K \frac{n_k}{N} \cdot F1_k, \quad (3.5)$$

где  $F1_{weighted}$  –  $F1$  со взвешенным усреднением,  $n_k$  – число объектов истинного класса  $k$  в наборе оценки,  $N$  – общее число объектов.

Стоит отметить, что наибольшее практическое значение для оценки нефтенасыщенности имеет атрибут «тип свечения», поскольку этот атрибут способен напрямую отражать факт наличия нефти на фотографии в УФ диапазоне. По этому признаку разработанная гибридная модель демонстрирует устойчивые результаты.

Наименее устойчивой оказалась задача определения характера свечения. Однако стоит отметить, что этот признак является наиболее субъективным ввиду того, что в производственной практике он описывает качественный рисунок распределения флуоресценции и зависит от индивидуальной интерпретации специалиста. Еще одним важным фактором, который повлиял на низкое значение

этого признака, является дисбаланс классов.

На рисунке 3.5 приведены два примера из валидационной выборки. Для каждого фрагмента отображаются: изображение в видимом диапазоне; изображение в УФ диапазоне (приведено к бинарному формату, так как различать УФ свечение на исходных изображениях может быть затруднительно); изображение в видимом диапазоне с прямоугольной областью интереса (детекция УФ свечения).

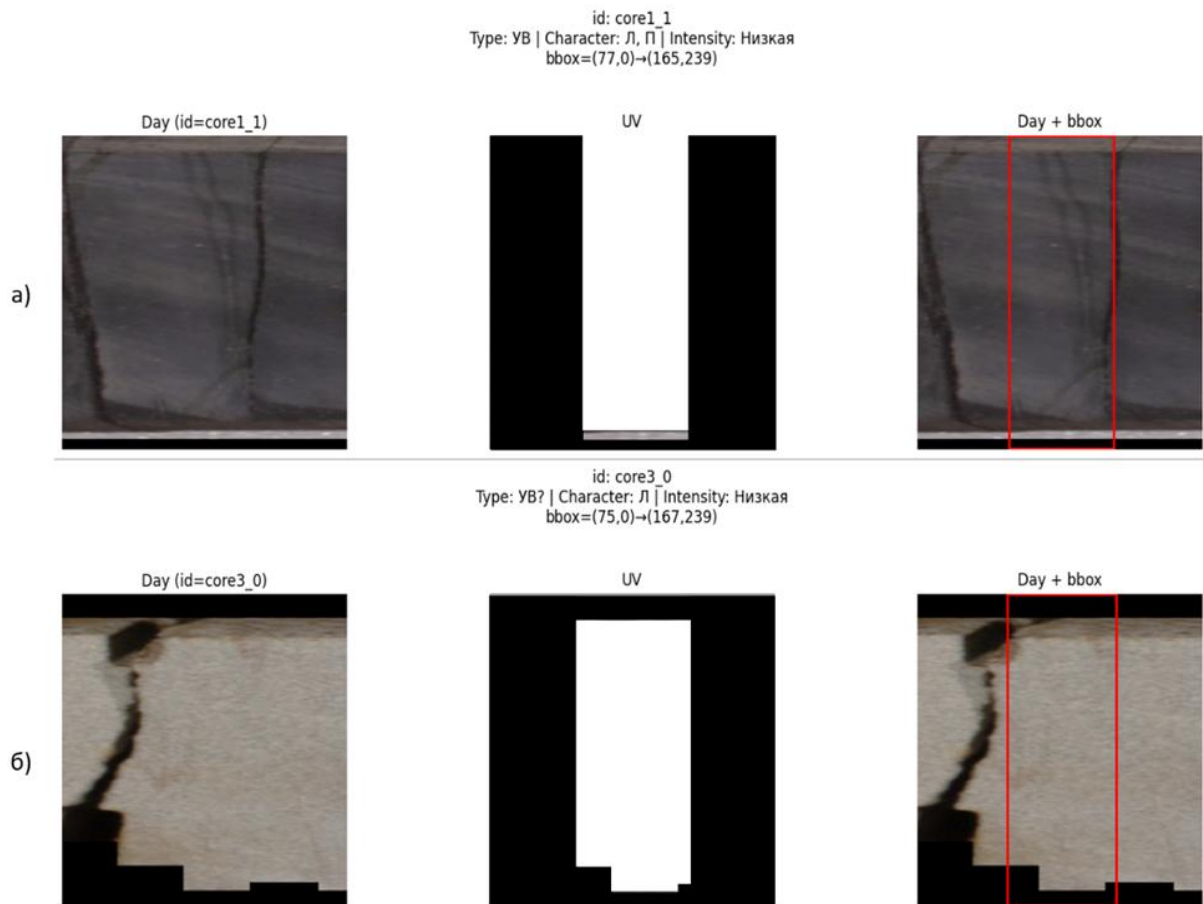


Рисунок 3.5 – Пример работы алгоритма оценки нефтенасыщенности для фрагментов а и б: Day – видимый диапазон; UV – УФ диапазон (приведен к бинарному формату); Day + bbox – результаты выделения зоны флуоресценции

Эти два примера отображают разные сценарии классификации свечения в УФ диапазоне. Первый пример отличается слабой выраженностью геометрии свечения, которое занимает достаточно узкую область. Однако разработанная модель все равно корректно локализует зону флуоресценции, после чего верно классифицирует тип и интенсивность. Во втором случае ситуация оказывается

несколько более сложной – на изображении присутствуют дополнительные помехи, связанные со сколами и неоднородностями породы. Но несмотря на это, модель дает корректный результат классификации – область интереса выделяется корректно и прогноз интенсивности остаётся устойчивым.

Приведенные примеры позволяют продемонстрировать то, что совместный анализ изображений в видимом и УФ диапазонах позволяет надёжно выявлять интервалы с наличием нефти, а также формировать воспроизводимое цифровое описание, пригодное для дальнейшей интерпретации.

### **3.6. Научная новизна и отличие от существующих подходов**

Научная новизна результатов, изложенных в данной главе, заключается не в замене традиционной интерпретации, а в переводе ключевого этапа – выявления нефтенасыщенных зон по УФ-съёмке – в воспроизводимую цифровую процедуру, совместимую с производственными данными. В большинстве известных работ по компьютерному зрению для керн анализ выполняется по изображениям в видимом диапазоне и направлен на литологическую классификацию; УФ-канал либо не используется, либо рассматривается как второстепенный. В представленном подходе УФ-съёмка включена в модель как равноправный источник признаков, что делает возможным автоматизированную оценку насыщения и сокращает влияние человеческого фактора.

Отличие предложенного решения состоит в комплексности конвейера и опоре на разработанную гибридную архитектуру сегментации. Алгоритм объединяет сегментацию изображений керн (устойчивое выделение области породы и зон флуоресценции), извлечение метаданных OCR и слияние с отчётами в единую цепочку формирования датасета. Это позволяет получать обучающие выборки из производственных материалов без трудоёмкой ручной подготовки, снижать влияние фоновых артефактов (коробка, заполнитель, маркировка) и обеспечивает трассируемость происхождения меток и интервалов.

На уровне модели новизна заключается в многозадачном анализе совмещённых данных «видимый + УФ диапазоны» в шестиканальном формате. Общий блок извлечения признаков извлекает признаки, согласованные между спектральными модальностями, а отдельные головы специализируются на типе, интенсивности и характере свечения. Такая постановка позволяет использовать взаимосвязь признаков и повышает устойчивость обучения на выборках ограниченного объёма, типичных для керновых исследований.

Наконец, полученное цифровое представление УФ свечения включает не только классификацию по 3 признакам, но и определение интервала глубин. Это создаёт основу для последующего количественного сопряжения с петрофизическими измерениями и для построения обобщаемых моделей, в которых признаки свечения используются как входные параметры интерпретации.

### **3.7. Выводы по третьей главе**

В третьей главе по итогам разработки и проведенного вычислительного эксперимента были получены следующие результаты:

- разработан алгоритм обучения модели классификации нефтенасыщенности. Сформирован воспроизводимый конвейер подготовки обучающего датасета на основе пар изображений «видимый диапазон + УФ». В его состав входят сегментация, извлечение метаданных и их сопоставление с отчетами. Использование такого конвейера позволяет заметно уменьшить трудозатраты при формировании датасета и сохраняет возможность дальнейшего расширения выборки;
- разработан алгоритм оценки нефтенасыщенности, основной частью которого является многозадачная шестиканальная модель на базе ResNet-34. Эта модель одновременно использует данные из видимого и УФ диапазонов. Такой подход обусловлен тем, что выделение нефтенасыщенных интервалов требует совместного анализа обоих типов изображений: съемка в видимом диапазоне

задает литологический контекст, а съемка в УФ диапазоне позволяет первично локализовать флуоресценцию как признак присутствия нефти;

- разработанная гибридная модель классифицирует УФ-флуоресценцию по трем признакам: тип, характер, интенсивность свечения и обеспечивает точность классификации: тип свечения - 0,90, интенсивность - 0,80, характер - 0,6.

Практическая значимость разработанной модели выражается в автоматизации выделения нефтенасыщенных зон и уменьшения влияния человеческого фактора.

## **Глава 4. Программная реализация интеллектуальной информационной системы**

В предыдущих главах были разработаны методы и алгоритмы работы с образцами керна. В настоящей главе эти методы и алгоритмы будут использованы в ИИС для ее программной реализации. Кроме того, в этой части работы рассмотрена сама концепция информационной системы, ее архитектура. Ниже рассматриваются основные сформированные требования к ИИС и принципы её создания. Предлагается использовать принципы модульного монолита и микросервисной архитектуры при разработке ПО системы.

### **4.1. Постановка задачи, решаемой ИИС**

ИИС призвана как автоматизировать работу специалиста-геолога, так и создать базу изображений керна и данных по ним, чтобы способствовать подбору скважин-аналогов.

Одной из проблем, с которыми сталкиваются высококвалифицированные специалисты-геологи, является значительный объем монотонной неавтоматизированной работы, требующей высокой концентрации внимания. Под этой работой понимается процесс обработки и анализа макрофотографий керна в видимом и УФ диапазоне.

Так выглядит часть процесса работы с изображениями керна в ручном режиме для одного образца керна:

1. Специалист открывает исходное изображение образцов керна; с помощью программных средства таких как Paint выделяет прямоугольник, в котором содержится этот образец.
2. После чего приближает изображение, чтобы разглядеть отметки кровли; на калькуляторе рассчитывает подошву/мощность.

3. Следующим шагом специалист сохраняет получившееся обрезанное изображение с данными расчета кровли/подошвы; точно так же сохраняет обрезанное изображение в УФ-диапазоне.
4. Каждому из изображений требуется присвоить название, отражающее значение кровли и подошвы и положить в директорию по месторождению/скважине.
5. Далее начинается процесс анализа фото, в ходе которого требуется определить: наличие УФ свечения; тип свечения; характер свечения; интенсивность свечения; интервал глубин, на котором происходит свечение. После чего требуется занести все полученные данные в таблицу Excel.

Этот алгоритм – для одного фрагмента керна, а на изображении их в среднем 6. Кроме того, эти образцы могут быть раздробленными, что значительно осложняет работу. Не стоит забывать еще и о том, что выполнение описанных действий вручную ведет к ошибкам ввиду человеческого фактора. Так, например, интенсивность свечения определяется очень субъективно (регламентированные нормы на этот вид анализа отсутствуют), что может привести к неверным результатам.

Также стоит отметить, что такой подход к хранению данных о керне не позволяет быстро производить поиск по уже выполненным отчетам анализа керна, которые могут храниться отдельно в системе электронного документооборота [99], а также не может использоваться для подбора скважин-аналогов по подобным параметрам.

Еще одним недостатком является очень большой объем занимаемого пространства, которое, кроме прочего, не отвечает требованиям безопасности, так как изображения керна и данные по нему хранятся на жестком диске в единственном экземпляре.

Для решения рассмотренных проблем была разработана интеллектуальная информационная система обработки, анализа и хранения образцов керна.

## 4.2. Концепция создания информационной системы

Прежде чем приступить к проектированию информационной системы, критически важно разработать подробное техническое задание. Этот документ является основой для согласования видения будущей системы и формализации требований к ней. Составление ТЗ требует системного подхода: требования должны формулироваться предельно четко, классифицироваться по заданным признакам, а их взаимозависимости – явно указываться. Каждое положение должно обладать атомарностью - то есть описывать одну неделимую сущность.

Среди признанных методологий инженерии требований для разработки ТЗ выделяется подход А. В. Симкина. Именно он лег в основу структурирования требований к информационной системе, предназначенной для анализа и хранения образцов керна. Как видно из таблицы 4.1, ключевые группы требований к системе включают функциональные блоки (F, FA), нефункциональные аспекты (I, DR, DF, A и пр.), а также варианты использования (V) [100].

Таблица 4.1 – Группы требований к информационной системе [100]

Символ	Группа требований
F	Общие функциональные требования
V	Варианты использования ИИС
FA	Требования к методам и алгоритмам обработки и анализа данных
I	Требования к интерфейсу пользователя
DR	Требования к составу данных
DF	Требования к представлению данных
D	Требования к описанию данных
R	Требования к отчетам
C	Требования к управлению справочниками и классификаторами
A	Требования к администрированию, управлению доступом и безопасностью системы
AR	Требования к правам доступа
TS	Требования к техническому обеспечению
IS	Требования к информационной безопасности системы

Ниже рассмотрены наиболее важные из представленных групп требований А.В. Симкина.

*Функциональные требования (группы F и FA)*

Требования к взаимодействию: Доступ к ИИС осуществляется через веб-браузер с минимально достаточным набором функций. Это позволяет разработать специализированные интерфейсы для решения задач сегментации, классификации и анализа изображений керна.

Сервер ИИС должен располагаться в корпоративной сети заказчика. Доступ по защищенному веб-адресу (требование группы F, взаимосвязанное с IS). Требуется процедура аутентификации пользователей (требование группы F, взаимосвязанное с A, AR, IS). Проверка корректности вводимых данных (например, при загрузке метаданных) выполняется как на стороне клиента (браузер), так и на сервере.

Требования к основным функциям: ИИС должна предоставлять набор функций (не меньший, чем при ручной работе оператора без данного приложения) для полного цикла работы с изображениями керна: сегментация образцов; ручная корректировка результатов сегментированных образцов; распознавание текста и коррекция (распознавание рукописных/печатных меток на коробках керна (кровля, подошва, номер керна – сервис) с последующей коррекцией ошибок распознавания и расчетом значений глубин; анализ УФ-свечения (определение и классификация УФ-свечения).

Кроме того, система должна позволять управлять данными:

- загружать пары изображений (видимый и УФ-диапазоны) с метаданными (скважина, месторождение, дата отбора и т.д.);
- хранить только сегментированные изображения керна для экономии пространства;
- хранить метаданные, координаты сегментации, результаты распознавания текста, результаты классификации УФ-свечения и данные, введенные пользователем.

Еще одним пунктом требований является функционал для интеграции с историческими данными – обогащение данных в БД информацией из ранее созданных ручных отчетов.

*Нефункциональные требования (группы DR, DF, D, R, C, A, AR, TS, IS)*

1. Производительность:

- обработка одного изображения (~4000×4000 пикселей) должна занимать не более 2 минут;
- поддержка нагрузки до 200 запросов в секунду;
- горизонтальное масштабирование сервисов обработки изображений с использованием Kafka [101] для асинхронной очереди задач.

2. Хранение данных [102-105]:

- MinIO – хранение исходных и сегментированных изображений. Оценка объема: 2 ТБ;
- MongoDB – хранение метаданных, результатов обработки, координат, УФ-классификации. Схемонезависимость для адаптации к разным заказчикам;
- Redis – кэш для ускорения доступа (например, к метаданным керна);
- PostgreSQL – хранение данных пользователей и авторизации.

3. Безопасность

Включает в себя: аутентификацию; локальное развертывание всех компонентов (серверов, БД, сервера очередей сообщений, хранилища) внутри сети заказчика.

Надежность и отказоустойчивость обеспечиваются за счет механизма подтверждения сообщений в Kafka только после успешной обработки задачи сервисом, а также за счет повторной обработки задач при сбоях. Кроме того, реализуется резервное копирование критичных данных (MongoDB, MinIO, PostgreSQL).

Результатом анализа требований к информационной системе стала схема в нотации C4 [106] уровня «контейнер», приведенная на рисунке 4.1.

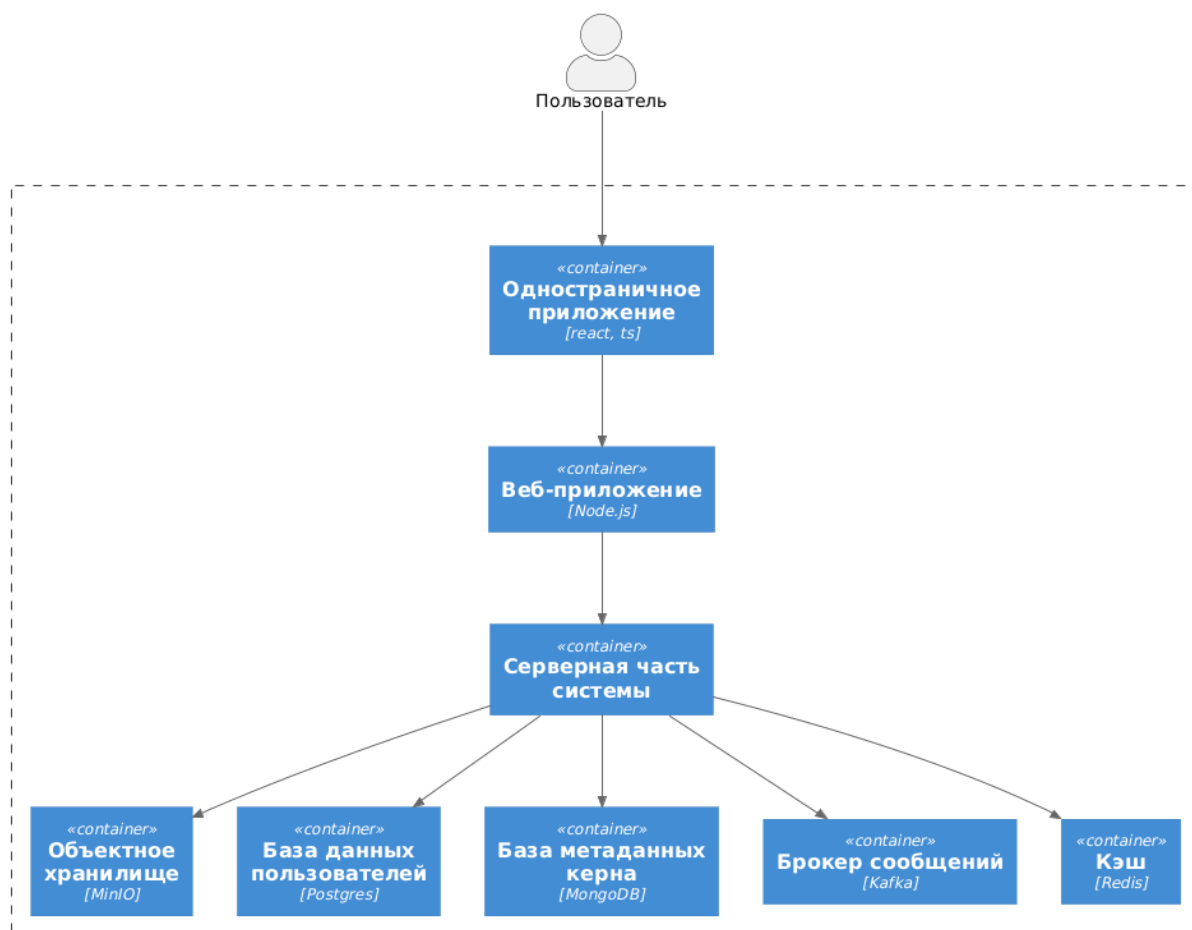


Рисунок 4.1 – Уровень «контейнер» в нотации C4 для ИИС

### 4.3. Архитектурные решения

В качестве основы системы была выбрана микросервисная архитектура, что обусловлено разнородностью решаемых задач. Система объединяет ресурсоемкие операции искусственного интеллекта, реализованные в основном на Python [107], высокопроизводительные вычислительные процессы на платформе .NET [108, 109], а также комплексное управление данными. Такой подход дает возможность использовать наиболее подходящие инструменты для каждой конкретной задачи: Python благодаря своей библиотечной экосистеме хорошо подходит для реализации алгоритмов сегментации и классификации, тогда как .NET обеспечивает эффективную оркестрацию вычислительных процессов. Схема решения в нотации C4 представлена на рисунке 4.2.

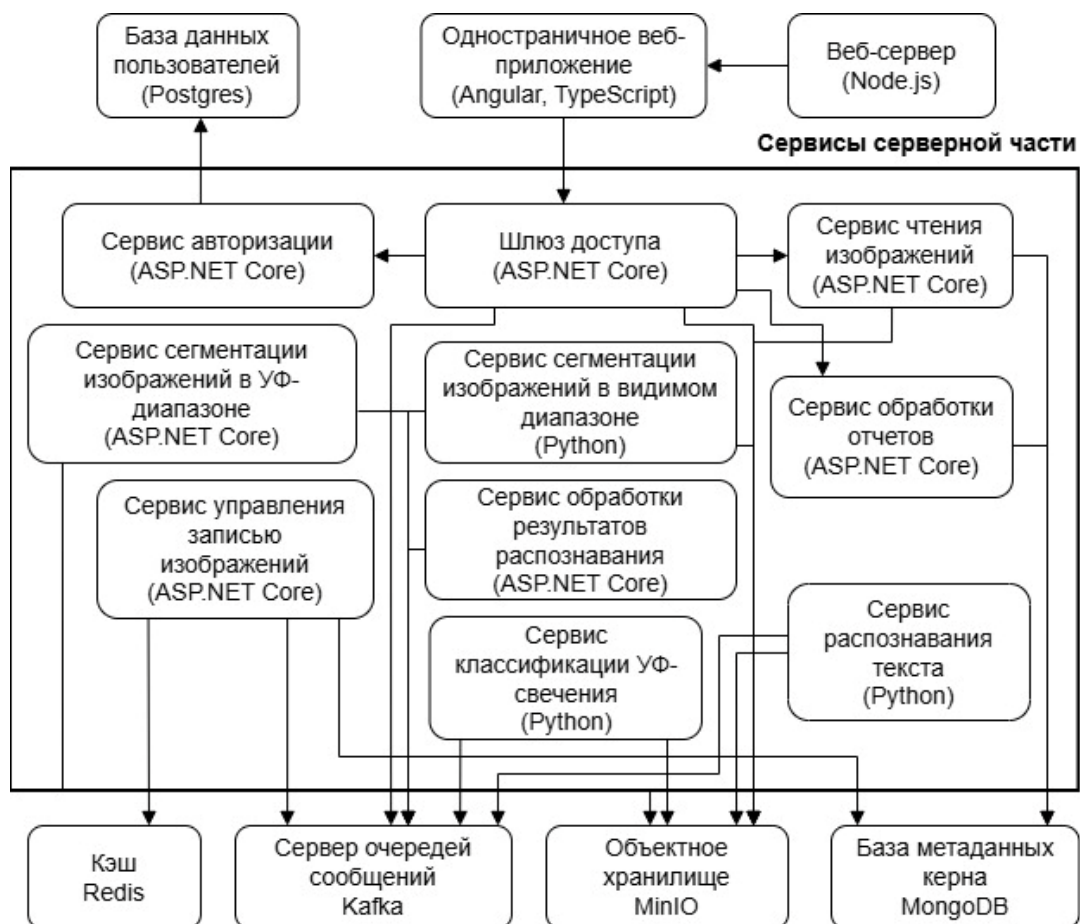


Рисунок 4.2 – Уровень «компонент» в нотации С4 для ИИС

Следствием такого решения стала возможность независимо масштабировать отдельные компоненты системы, например увеличивать число экземпляров сервиса сегментации изображений в видимом диапазоне в периоды повышенной нагрузки.

Разработанная архитектура также обеспечивает отказоустойчивость за счет изоляции сервисов. Другими словами, сбой в работе сервиса распознавания текста не приводит к нарушению процессов сегментации изображений, поскольку данные сохраняются в кеше, а взаимодействие между компонентами организовано асинхронно через платформу Kafka. Кроме того, микросервисный подход упрощает дальнейшее сопровождение системы и делает ее развитие более гибким, поскольку разные команды - например, геологи, работающие над алгоритмами сегментации, и инженеры, отвечающие за инфраструктуру, - могут параллельно работать с независимыми сервисами.

Как было сказано ранее взаимодействие между сервисами реализовано посредством асинхронной коммуникации через Apache Kafka. Применение шаблона проектирования «очередь задач» обеспечивает выполнение длительных операций, таких как сегментация изображений и оптическое распознавание символов, в асинхронном режиме, что исключает блокировку пользовательского интерфейса. Типичный поток обработки включает последовательность: «Шлюз доступа» → Kafka → «Сервис управления записью изображений» → Kafka → «Сервис сегментации изображений в видимом диапазоне» → MinIO → Kafka → «Сервис классификации УФ-свечения» → Kafka → «Сервис управления записью изображений».

Для гарантированной доставки сообщений и предотвращения потери данных при сбоях используются механизмы подтверждения доставки и идемпотентной обработки сообщений. Kafka позволяет системе обрабатывать пиковые нагрузки без деградации производительности.

Выбор технологий для реализации сервисов был обусловлен их соответствием специфическим требованиям. Сервисы «Шлюз доступа», «Сервис авторизации», «Сервис управления записью изображений», «Сервис обработки отчетов», «Сервис сегментации изображений в УФ-диапазоне», «Сервис чтения изображений» разработаны на ASP.NET Core, что обеспечивает высокую производительность, а также предоставляет встроенную поддержку внедрения зависимостей, гибкой конфигурации, асинхронного программирования и совместимость со смешанной инфраструктурой заказчика (Windows/Linux).

Сервисы искусственного интеллекта («Сервис сегментации изображений в видимом диапазоне», «Сервис классификации УФ-свечения», «Сервис распознавания текста») реализованы на Python, что обусловлено богатой экосистемой специализированных библиотек машинного обучения (TensorFlow/Keras для моделей сегментации типа U-Net, OpenCV для обработки изображений, EasyOCR для распознавания текста) и упрощенной интеграцией с графическим процессором через CUDA.

Пользовательский интерфейс реализован в виде одностраничного приложения, разработанного с использованием Angular и TypeScript. Использование TypeScript позволяет сделать работу системы более устойчивой за счет использования строгой типизации, которая помогает снижать число ошибок при обработке сложных геологических данных, включая координаты и интервалы глубин. Кроме того, это дает возможность реализовывать достаточно сложные средства визуализации [110].

Центральным компонентом обработки выступает «Сервис управления записью изображений», реализующий шаблон управления распределенными транзакциями. Для агрегирования промежуточных результатов, поступающих от независимых микросервисов сегментации, распознавания текста и классификации, используется Redis как временное хранилище состояния до того момента, когда все данные по конкретному образцу будут полностью подготовлены. После этого агрегированный объект записывается в документоориентированную СУБД MongoDB, которая отвечает за постоянное хранение данных. Выбор MongoDB связан с динамической схемой геологических метаданных, которая может меняться в зависимости от месторождения и требования заказчика.

Исходные полноразмерные фотографии и нарезанные образцы сохраняются в объектном хранилище MinIO, которое поддерживает совместимость с протоколом Amazon S3. Логика работы с хранилищем выбрана таким образом, чтобы, с одной стороны, можно было гибко задавать правила хранения данных на разных этапах их жизненного цикла, а с другой - уменьшать затраты дискового пространства. Для этого в системе сохраняются не полные исходные изображения, а только информативные области, содержащие керн, тогда как фон, связанный с изображением коробки, в хранилище не записывается.

#### **4.4. Оценка эффективности хранения сегментированных изображений керна**

Одной из практических задач, решаемых разработанной интеллектуальной информационной системой, является сокращение объема дискового пространства, необходимого для хранения цифровых изображений керна. Актуальность этой задачи обусловлена тем, что в процессе лабораторных исследований и промышленной эксплуатации цифровых кернохранилищ накапливаются большие массивы макрофотографий, выполненных в высоком разрешении. Часть таких изображений приходится на фоновые области, не содержащие полезной геологической информации: пустое пространство ящиков, технологические элементы, линейки, маркировки. Вследствие этого хранение исходных изображений в полном объеме приводит к избыточному расходованию дискового пространства.

В рамках настоящей работы сокращение объема хранения достигается за счет предварительной сегментации изображений керна и последующего сохранения только значимой области, соответствующей выделенному образцу породы. Экономия дискового пространства достигается не только за счет исключения фоновой информации как таковой, но и за счет повышения эффективности сжатия при сохранении изображений в формате PNG. После сегментации пиксели фона принимают нулевые значения, вследствие чего в изображении появляются большие однородные области с повторяющимися значениями. Такие области обладают значительно лучше сжимаются стандартными алгоритмами без потерь, применяемыми в PNG. Такой подход позволяет исключить из хранимых данных значительную часть фоновой информации, не участвующей в дальнейшем анализе.

Целью данного подраздела является количественная оценка эффективности предложенного подхода с точки зрения уменьшения объема хранимых данных по сравнению с традиционным сохранением исходных изображений целиком.

Для проведения оценки был выполнен сравнительный анализ двух вариантов хранения цифровых данных:

1. традиционный подход, при котором сохраняется полное исходное изображение керна в исходном разрешении;
2. предлагаемый подход, при котором после выполнения сегментации сохраняется только область, содержащая образец керна.

При этом для обеспечения корректности сравнения использовались изображения одного и того же набора образцов, полученные в одинаковых условиях съемки и имеющие одинаковый исходный формат хранения. Для каждого изображения определялись:

- объем исходного файла;
- объемы файлов после сегментации и сохранения выделенных областей;
- относительное сокращение объема хранения.

Относительное сокращение объема хранения рассчитывалось по формуле

$$\Delta V = \frac{V_{orig} - V_{seg}}{V_{orig}} \cdot 100\%, \quad (4.1)$$

где  $\Delta V$  – относительное сокращение объема хранения,  $V_{orig}$  – объем исходного изображения,  $V_{seg}$  – объем изображения после сегментации и сохранения только значимой области.

Для интегральной оценки эффективности по всей выборке рассчитывались суммарные объемы хранения исходных и сегментированных данных:

$$\Delta V_{sum} = \frac{\Sigma V_{orig} - \Sigma V_{seg}}{\Sigma V_{orig}} \cdot 100\%, \quad (4.2)$$

где  $\Delta V_{sum}$  - относительное сокращение объема хранения по всем рассмотренным образцам. Результаты эксперимента представлены в таблице 4.2.

Таблица 4.2 – Сравнение объёма хранения исходных и сегментированных данных

Показатель	Значение
Количество изображений в эксперименте, шт.	32
Суммарный объем исходных изображений, МБ	419,2
Суммарный объем сегментированных изображений, МБ	313,1
Средний объем исходного изображения, МБ	13,1

*Продолжение таблицы 4.2*

Показатель	Значение
Средний объем соответствующего набора сегментированных изображений, МБ	9,8
Среднее сокращение объема хранения	25,2

Анализ полученных результатов показывает, что использование сегментации в качестве предварительного этапа хранения цифровых изображений позволяет заметно уменьшить объем сохраняемых данных. По результатам эксперимента суммарный объем хранения уменьшился с 419,2 МБ до 313,1 МБ, что соответствует сокращению на 25,3%. Среднее уменьшение объема одного изображения составило 25,2%, а диапазон изменения по отдельным образцам находился в пределах от 20% до 30%. Полученный разброс объясняется тем, что эффективность сегментации с точки зрения экономии памяти зависит от структуры конкретного образца, заполнения кадра керном, количества фоновой области, а также от наличия раздробленных фрагментов.

Практическая значимость заключается, во-первых, в уменьшении потребности в дисковом пространстве при долговременном хранении архивов изображений; во-вторых, в снижении нагрузки на систему передачи и обработки данных, что повышает общую производительность интеллектуальной информационной системы. Это особенно важно при масштабировании решения и накоплении больших массивов изображений в ходе промышленной эксплуатации.

Таким образом, проведенный эксперимент подтверждает, что переход от хранения полных исходных изображений к хранению прямоугольных фрагментов, ограничивающих сегментированный образец керна, является эффективным способом оптимизации цифрового кернаохранилища. Внутри такого фрагмента сохраняются только пиксели, принадлежащие образцу, тогда как пиксели вне маски заполняются нулевым фоном. За счёт уменьшения размеров сохраняемой области и эффективного сжатия однородных фоновых участков форматом PNG достигается сокращение объёма хранения без потери значимой аналитической информации.

#### 4.5. Алгоритм обработки результатов OCR

Одной из задач ИИС было распознавание номеров образцов, значений кровли и подошвы на изображениях. Пример изображения, на котором требуется распознать отметки подошвы керна приведен на рисунке 4.3.



Рисунок 4.3 – Часть изображения со значениями подошвы образцов керна

Проблема заключается в том, что кровля и подошва написаны рукописным текстом, соответственно, их сложно распознать стандартными OCR инструментами.

Для решения задачи были проанализированы три наиболее эффективные на текущий момент технологии: Tesseract OCR, CRNN (EasyOCR, Keras-OCR), TrOCR [111, 112]. Анализ проводился на основе определения в процентах количества верно определенных значений на одном и том же датасете в виде изображений керн. Были получены результаты, представленные в таблице 4.3.

Таблица 4.3 – Результаты распознавания значений кровли/подошвы

Технология	Успешно распознанных значений, %
Tesseract OCR	44,5
EasyOCR	72,4
Keras-OCR	66,2
TrOCR	69,4

Как видно из таблицы 4.3, ни одна из рассмотренных OCR-технологий не обеспечивает достаточной надежности для прямого автоматического определения значений кровли и подошвы без дополнительной валидации. Это связано с тем, что каждое значение глубины содержит, как правило, 5-6 символов, и даже при сравнительно высокой точности распознавания отдельных цифр ошибка хотя бы в одном символе делает итоговое значение непригодным для практического использования. Кроме того, для корректной интерпретации необходимо одновременно верно определить как минимум два связанных значения – кровлю и подошву, а также обеспечить корреляцию с соседними интервалами. По этой причине был разработан алгоритм валидации и постобработки результатов OCR (приложение Б).

Алгоритм включает последовательность взаимосвязанных этапов. На этапе парсинга входных данных выполняется обработка двух типов структур:

1. Строки формата «Керн-123, н.к., 2020,1-2025,9» (содержащие номер образца – «Керн-123», позиционную метку – «н.к.», а также диапазон глубин – «2020,1-2025,9») над некоторыми образцами керна. Эти строки подвергаются обработке с применением регулярных выражений. Извлекаются ключевые элементы: идентификатор образца, позиционный маркер («н.к.» - «начало керна», «п.к.» - «продолжение керна», «к.к.» - «конец керна»), диапазон глубин и параметр N (количество цифр в целой части числа).
2. Строки формата «2015.9» справа и слева от образцов керна, обозначающие кровлю и подошву конкретного образца.

Следующим этапом начинается работа с распознанными данными. Во-первых, требуется распознать числовые последовательности. Проблема

заключается в том, что, например, значение интервала глубин «2020,1» из особенностей рукописного ввода может быть распознано как «20201». Чтобы решить эту проблему применяется правило реконструкции: если количество цифр превышает N, первые N цифр интерпретируются как целая часть, остальные – как дробная, формируя число с плавающей точкой (например, 2020,15 для N равно 4). Количество же цифр в N мы можем установить исходя из того, что в подавляющей большинстве случаев керн отбирается с глубин более 1000 м, а глубины свыше 9999 м являются чрезвычайно большими для нефтяной скважины. Результатом этого этапа являются структурированные метаданные с пространственными координатами.

Сопоставление данных предполагает формирование словаря координат, где ключом выступает индекс образца керна на изображении, а значением – список распознанных чисел с их координатами и предварительно определенной позиционной принадлежностью (кровля/подошва). Метаданные из текстовых описаний привязываются к образцам на изображении через координатные соответствия. На данном этапе валидация распознанных чисел (например, соответствие определенных значений кровли/подошвы и корреляция между ними) не производится.

После этого идет определение принадлежности распознанных значений к кровле или подошве. Другими словами, среди полученных в ходе OCR отметок глубин, относящихся к образцу керна, нам требуется понять что из этих отметок является кровлей, что - подошвой. При этом надо учитывать, что распознанные значения могут быть недостоверны. Для решения этой задачи используются два правила:

1. Логическое правило опирается на соотношение самих значений: меньшее значение принимается за кровлю, большее - за подошву. Если между интерпретациями возникает расхождение, приоритет сохраняется за логическим правилом.

2. Геометрическое правило использует позицию числа относительно центра образца по оси X: левостороннее расположение указывает на кровлю, правостороннее – на подошву. Здесь есть допущение, что фотографирование образцов керн – крайне точный процесс и специалист геолог не перевернет коробку с керном при фотографировании.

Проверка количества значений предусматривает три сценария:

1. Если обнаружены ровно два значения (которые потенциально соответствуют кровле и подошве), то такие данные помечаются как условно достоверные и требуют ручного подтверждения оператором.
2. Если значений меньше двух, образец считается нераспознанным и переводится на полный ручной ввод.
3. В том же случае, если значений оказывается больше двух, запускается алгоритм оценки достоверности.

Оценка достоверности для случаев избыточных значений включает построение таблицы баллов, основанной на качестве распознавания (уверенность OCR) и согласованности с соседними образцами. Критически важна проверка консистентности: подошва верхнего образца должна соответствовать кровле нижнего в пределах допустимой погрешности глубины. Несовпадение снижает балл достоверности для обоих значений. Дополнительно рассчитывается масштабный коэффициент (пиксели на метр) по формуле:  $scale = L / (Bottom - Roof)$ , где  $L$  - длина одного столбца керн в пикселях,  $Bottom$  – значение глубины подошвы столбца керн,  $Roof$  – значение глубины кровли столбца керн; позволяющий оценить погрешность глубины через пространственное смещение:  $dif = (X_{roof}^1 - X_{roof}^2) / scale$ , где  $dif$  - погрешность при расчете глубин образцов по изображению,  $X_{roof}^1$ ,  $X_{roof}^2$  – координаты по горизонтальной оси (принимается, что керн уложен как на рисунке 1.1) кровли двух соседних столбцов керн на одном изображении.

Финализация результатов предусматривает два подхода. При наличии достоверных значений (которые берутся как эталонные и используются при расчете дальше – обозначена индексом ref) недостающие глубины рассчитываются

интерполяцией:  $Roof = Roof_{ref} + (coord_x - coord_{ref}) / scale$ , где  $Roof_{ref}$  – эталонная глубина,  $coord_{ref}$  – координата по горизонтальной оси для  $Roof_{ref}$  а  $coord_x$  – координата целевого образца. Важным является то, что при отсутствии достоверных значений данные маркируются как ошибочные и передаются на ручной ввод. Другими словами, в случае если нам не удалось достоверно распознать и пересчитать отметки глубин, то мы не будем вписывать данные, в которых не уверены, а попросим оператора в ручном режиме написать значение кровли и подошвы для одного из образцов.

#### 4.6. Выводы по четвертой главе

В главе, посвященной программной реализации интеллектуальной информационной системы для обработки, анализа и хранения образцов керна, были получены результаты, имеющие прикладное значение. В ходе работы была сформирована общая концепция системы и разработана ее архитектура, ориентированная на преодоление существенных ограничений традиционных подходов, используемых в работе геологов.

Архитектурной основой системы стала комбинированная модель, сочетающая принципы микросервисного подхода и модульного монолита. Выбор такого решения был связан с необходимостью сохранить технологическую гибкость, но при этом не усложнять систему. За счет этого удалось использовать наиболее подходящие инструменты для разных классов задач. Так, Python с библиотеками машинного обучения (TensorFlow/Keras, OpenCV) применялся для ресурсоемких операций искусственного интеллекта, связанных с сегментацией, классификацией и распознаванием текста, в то время как .NET Core использовался для высокопроизводительной оркестрации процессов и реализации бизнес-логики системы. Такой подход дал возможность отдельно организовать вычислительно сложные и инфраструктурные задачи, при этом общая архитектура системы сохранила целостность.

Дополнительная устойчивость и стабильность работы системы обеспечивались за счет асинхронного взаимодействия компонентов через брокер сообщений Kafka. Это дало возможность выстроить обработку данных без жесткой зависимости сервисов друг от друга, повысить отказоустойчивость и сделать работу системы более надежной при пиковых нагрузках.

Основные аспекты реализованной системы представлены в таблице 4.4.

Таблица 4.4 – Результаты и решения реализованной ИИС

Аспект	Результаты и решения	Технологии
Архитектура	<ul style="list-style-type: none"> <li>- Архитектура гибридная: микросервисы и модульный монолит</li> <li>- Асинхронная обработка через Kafka</li> <li>- Горизонтальное масштабирование</li> </ul>	<ul style="list-style-type: none"> <li>- Python (ML), .NET Core (оркестрация)</li> <li>- Angular/TypeScript (интерфейс)</li> <li>- Kafka (очереди задач)</li> </ul>
Хранение данных	<ol style="list-style-type: none"> <li>1. Сегментированные изображения</li> <li>2. Метаданные, результаты анализа (гибкая схема)</li> <li>3. Кэширование</li> <li>4. Пользователи</li> </ol>	<ol style="list-style-type: none"> <li>1. MinIO</li> <li>2. MongoDB</li> <li>3. Redis</li> <li>4. PostgreSQL</li> </ol>
OCR-обработка	<p>Комбинированный подход:</p> <ul style="list-style-type: none"> <li>- Распознавание: EasyOCR (72.4% точности)</li> <li>- Валидация: геометрические/логические правила + интерполяция глубин</li> </ul>	<ul style="list-style-type: none"> <li>- Контекстная коррекция чисел</li> <li>- Проверка согласованности с соседними образцами (<math>\pm 0.2</math> м)</li> </ul>
Научная новизна	<ul style="list-style-type: none"> <li>- Контекстная коррекция OCR</li> <li>- Методика хранения сегментированных изображений</li> </ul>	

Ключевые архитектурные решения включают:

- оптимальный выбор технологий хранения: документоориентированная СУБД MongoDB для гибкого управления разнородными метаданными, MinIO (S3-совместимое хранилище) для эффективного хранения изображений, Redis для кэширования и PostgreSQL для надежного управления пользователями и правами доступа;

- реализацию механизмов обеспечения надежности и безопасности: «exactly-once» семантику обработки сообщений в Kafka, репликацию данных, развертывание всей системы в защищенном периметре сети заказчика;
- обеспечение приемлемой производительности обработки изображений высокого разрешения за счет GPU-ускорения, параллельной обработки и горизонтального масштабирования.

Реализованная ИИС не только автоматизирует рутинные операции, снижая влияние человеческого фактора и время обработки, но и формирует структурированную цифровую базу данных образцов керна, что является критически важным фундаментом для решения задач подбора скважин-аналогов и повышения эффективности геологоразведочных работ.

## ЗАКЛЮЧЕНИЕ

Настоящая диссертационная работа посвящена решению актуальной научно-практической проблемы автоматизации анализа и оптимизации хранения образцов керна в нефтегазовой отрасли. Исследование было мотивировано возрастающими объемами данных, трудоемкостью и субъективностью традиционных методов анализа, а также отсутствием эффективных инструментов для комплексной обработки изображений керна в видимом и ультрафиолетовом диапазонах.

В ходе выполнения работы была достигнута основная цель – разработана и реализована система классификации и хранения образцов керна на основе методов машинного обучения. При этом были получены следующие основные результаты:

1. Проведен анализ применения нейросетевых технологий для исследования изображений образцов керна, который показал, что в настоящее время при анализе изображений керна, как правило, рассматриваются данные в видимом диапазоне. В то же время ультрафиолетовое свечение позволяет выделять на изображениях нефтенасыщенные участки, которые не видны при видимом освещении.
2. Показано, что первым шагом к решению данной проблемы является введение автоматической сегментации изображений керна, где сначала необходимо в видимом диапазоне отделить породу от фона и других объектов, а уже затем провести сегментацию в ультрафиолете. Для этого прежде всего необходимо иметь сбалансированную архитектуру нейросети, обеспечивающую надежную сегментацию изображений керна.
3. Создана и протестирована гибридная архитектура нейронной сети на основе U-Net. Внедрение вложенных плотных пропускных связей, глубинно-разделяемых сверток, остаточных блоков и блоков внимания позволило существенно повысить точность сегментации (увеличение индекс Жаккара на 8% в относительном выражении) и сократить время обработки на 33%, что

критически важно для работы с изображениями высокого разрешения и сложными геологическими структурами.

4. Обоснован и разработан алгоритм оценки нефтенасыщенности на основе комплексного анализа изображений в видимом и ультрафиолетовом диапазонах, который обеспечил объективизацию результатов и повышение точности оценки ключевых параметров. Так точность классификации типа свечения составила 0,9, интенсивности – 0,8, характера – 0,6.
5. Разработана эффективная методика хранения цифровых изображений образцов керна. Использование сегментированных данных вместо исходных изображений позволило достичь сокращения требуемого объема цифрового хранилища на 20-30%, обеспечив при этом возможность эффективного поиска и анализа информации.

Достоверность полученных результатов подтверждена корректной постановкой задач, использованием современных методов цифровой обработки изображений, компьютерного зрения, машинного обучения и математического моделирования, а также тестированием на модельных и экспериментальных данных.

Результаты диссертационной работы прошли успешную апробацию на ряде авторитетных российских и международных конференций и отражены в 9 научных публикациях, включая рецензируемые журналы, индексируемые в базах Scopus и Web of Science. Основные положения работы, вынесенные на защиту, получили полное научное и экспериментальное подтверждение.

Результаты диссертационной работы используются в обществе с ограниченной ответственностью научно-аналитический центр «Недра» (г. Томск) для автоматизации процесса и повышения качества оценок при прогнозе характера насыщения резервуаров.

**СПИСОК СОКРАЩЕНИЙ И ОПРЕДЕЛЕНИЙ**

1. Керн – цилиндрический образец горной породы, извлекаемый из скважины; служит прямым источником информации о составе, строении и свойствах пласта.
2. Геологический разрез – последовательность пород по глубине, отражающая их строение, состав и взаимное положение.
3. Углеводороды – органические соединения, составляющие основу нефти и газа.
4. Осадконакопление – процесс накопления минерального и органического материала с последующим образованием осадка.
5. Вещественный состав породы – совокупность минералов и органического вещества, из которых состоит порода.
6. Пласт – слой горной породы, относительно однородный по составу и условиям образования.
7. Коллектор – порода, которая может вмещать флюиды в порах и пропускать их через себя.
8. Постседиментационные изменения – изменения породы после ее первоначального накопления и захоронения.
9. Растворение неустойчивых зерен – разрушение менее устойчивых минералов под действием флюидов, иногда приводящее к образованию новых пустот.
10. Вторичная пористость – пористость, возникшая не при осадконакоплении, а позднее, например из-за растворения минералов.
11. Перекристаллизация – изменение размеров и формы минеральных зерен без существенного изменения химического состава вещества.
12. Коллекторские свойства – свойства породы, определяющие ее способность вмещать и пропускать флюиды.
13. Каверны выщелачивания – крупные пустоты, образованные растворением части породы.

14. Диагенез – совокупность процессов преобразования осадка в породу при сравнительно невысоких температурах и давлениях.
15. Прогностическая геологическая модель – модель строения недр, используемая для прогноза распределения пород, свойств и флюидов.
16. Насыщенность – доля порового пространства, занятая конкретным флюидом.
17. Флюид – подвижная среда в порах породы; в нефтегазовой геологии это прежде всего вода, нефть и газ.
18. Петрофизические исследования – лабораторные исследования, направленные на измерение физических свойств породы как коллектора.
19. Фильтрационно-емкостные свойства – совокупность свойств, характеризующих вместимость породы для флюидов и возможность их движения.
20. Пористость – доля объема пор в общем объеме породы.
21. Проницаемость – способность породы пропускать через себя флюиды.
22. Относительная фазовая проницаемость – мера того, насколько хорошо каждая из фаз, например вода и нефть, движется в породе при совместном присутствии.
23. Литолого-седиментологические исследования – исследования состава, строения и условий образования осадочных пород.
24. Шлиф – очень тонкий срез породы, подготовленный для изучения под микроскопом.
25. Литолого-фацциальное описание – описание пород одновременно по их составу и по условиям образования.
26. Фацция – комплекс признаков породы, отражающий условия ее образования.
27. Флюидоупор – малопроницаемая или практически непроницаемая порода, препятствующая перемещению флюидов.
28. Неоднородность коллектора – изменение свойств породы по разрезу или по площади, из-за которого пласт ведет себя неравномерно.
29. Каверна – относительно крупная пустота в породе.
30. ГИС (геофизические исследования скважин) – совокупность методов измерений параметров пород и флюидов непосредственно в скважине.

31. Литологические разности – разновидности пород, различающиеся по составу, цвету, текстуре или другим признакам.
32. Каротаж – запись по глубине параметров, измеренных в скважине специальной аппаратурой.
33. Гранулометрический состав – распределение зерен породы по размерам.
34. Окатанность зерен – степень сглаженности зерен, отражающая длительность и условия переноса.
35. Биотурбация – нарушение первоначальной слоистости осадка организмами, обитавшими в нем или на его поверхности.
36. Карбонатная порода – порода, сложенная главным образом карбонатными минералами, например кальцитом или доломитом.
37. Линза – ограниченное по размерам тело породы, которое выклинивается в стороны.
38. Резистивиметрия – метод каротажа, основанный на измерении электрического сопротивления пород.
39. Зависимость «керна-каротаж» – связь между прямыми лабораторными данными по керну и косвенными геофизическими данными.
40. Пропласток – сравнительно тонкий слой в составе более крупной толщи пород.
41. Литотип – тип породы, выделяемый по устойчивому набору признаков состава и строения.
42. Свита – крупное стратиграфическое подразделение, объединяющее породы сходного возраста и состава.

**СПИСОК ИСПОЛЬЗУЕМОЙ ЛИТЕРАТУРЫ**

1. Pratama M.A., Al Qoroni O., Rahmatullah I.K., Jameel M.F., Weijermars R. Probabilistic production forecasting and reserves estimation: Benchmarking Gaussian decline curve analysis against the traditional Arps method (Wolfcamp shale case study) // *Geoenergy Science and Engineering*. – 2024. – Vol. 232. – Pt. A. – Art. 212373. – DOI 10.1016/j.geoen.2023.212373.
2. Ma Y., Cai X., Yun L., Li Z., Li H., Deng S., Zhao P. Practice and theoretical and technical progress in exploration and development of Shunbei ultra-deep carbonate oil and gas field, Tarim Basin, NW China // *Petroleum Exploration and Development*. – 2022. – Vol. 49. – No. 1. – P. 1–20. – DOI 10.1016/S1876-3804(22)60001-6.
3. Gogoi T., Alam J., Chatterjee R. Mineralogy and pore structure characterization of Lower Oligocene to Early Miocene formations in parts of Assam-Arakan basin, North East India // *Current Science*. – 2022. – Vol. 123. – No. 2. – P. 202–213. – DOI 10.18520/cs/v123/i2/202-213.
4. Density and magnetic susceptibility of major rock types within the Abitibi greenstone belt: a compilation with examples of its use in constraining inversion / E. Eshaghi, R. Vayavur, R.S. Smith, C. Mancuso, F. Della Justina, J. Ayer // *Exploration Geophysics*. – 2023. – Vol. 54. – Iss. 6. – P. 647–669.
5. Amigun J.O., Ako B.D. Rock density – a tool for mineral prospection: a case study of Ajabanoko Iron Ore Deposit, Okene SW Nigeria // *Pacific Journal of Science and Technology*. – 2009. – Vol. 10. – Iss. 2. – P. 733–741.
6. Zappone A., Kissling E. SAPHYR: Swiss Atlas of Physical Properties of Rocks: the continental crust in a database // *Swiss J. Geosci.* – 2021. – Vol. 114. – Iss. 13. – DOI 10.1186/s00015-021-00389-3.
7. Гурбатова И.П., Плотников В.В., Попов Н.А., Сысоев И.В. Особенности изучения фильтрационных характеристик ориентированного керна сложнопостроенных карбонатных коллекторов // *Вестник ПНИПУ. Геология. Нефтегазовое и горное дело*. – 2013. – № 9. – С. 79-86.

8. Петрофизические методы исследования кернового материала (Терригенные отложения) / М.К. Иванов, Ю.К. Бурлин, Г.А. Калмыков, Е.Е. Карнюшина, Н.И. Коробова. – М.: Изд-во Моск. ун-та, 2008. – Кн. 1. – 112 с.
9. Петрофизические методы исследования кернового материала. Кн. 2: Лабораторные методы петрофизических исследований кернового материала / М.К. Иванов, Г.А. Калмыков, В.С. Белохин, Д.В. Корост, Р.А. Хамидуллин. – М.: Изд-во Моск. ун-та, 2008. – 113 с.
10. Тиаб Дж., Доналдсон Эря Ч. Петрофизика: теория и практика изучения свойств горных пород и движения пластовых флюидов / Перевод с английского. – М.: ООО «Премииум Инжиниринг», 2009. – 868 с.
11. Patel A.K., Snehamoy C. Computer vision-based limestone rock-type classification using probabilistic neural network // *Geoscience Frontiers*. – 2016. – Vol. 7. – P. 53–60.
12. 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. – Vol. 8. – P. 737–755.
13. 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.
14. Ивченко А.В., Барабошкин Е.Е., Исмаилова Л.С. и др. Литологическая интерпретация фотографий керна на основе компьютерного анализа // *Международная научная конференция «IEEE Northwest Russia Conference on Mathematical Methods in Engineering and Technology: ММЕТ NW 2018»*. – Санкт-Петербург: СПбГЭТУ «ЛЭТИ», 2018. – С. 430–433.
15. Артамонов В.П., Каюров Н.К. Автоматизация алгоритмов предобработки и анализа фотографий керна для целей процесса макро- и литологического описания // *Тезисы докладов 3-й научно-практической*

конференции «Интеллектуальный анализ данных в нефтегазовой области». – Новосибирск, 2022. – URL: <https://libgeo.ru/library/data-science?filter=302> (дата обращения: 04.06.2023).

16. Дьячков С.М. Автоматическое определение породы по фотографиям керна современными методами машинного обучения / С.М. Дьячков [и др.] // Вестник Тюменского государственного университета. Серия: Физико-математическое моделирование. Нефть, газ, энергетика. – 2021. – Т. 7. – № 4(28). – С. 181–198.

17. 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.

18. Distribution of petrophysical properties for sandy-clayey reservoirs by fractal interpolation / M. Lozada-Zumaeta, R.D. Arizabalo, G. Ronquillo-Jarillo, E. Coconi-Morales, D. Rivera-Recillas, F. Castrejon-Vacio // Nonlin. Processes Geophys. – 2012. – Vol. 19. – P. 239–250.

19. Hamd-Allah S.M., Abbas O.S., Dhaidan M.K. Distribution of petrophysical properties based on conceptual facies model, Mishrif Reservoir/South of Iraq // Journal of Petroleum Research and Studies. – 2022. – Vol. 12. – P. 51–70.

20. Quinto S., Torino P., Weltje G.J. How to integrate basin-scale information into reservoir models // Annual EAGE Conference and Exhibition incorporating SPE Europec. – 2013.

21. Mohammad A. Al-Khalifa, Payenberg Tobias H.D., Lang S.C. Overcoming the challenges of building 3D stochastic reservoir models using conceptual geological models – a case study // SPE Middle East Oil and Gas Show and Conference. – 2007.

22. Petrophysics analysis for determination of density porosity and neutron-density porosity on carbonate rock in East Java Basin / D. Juliantu, Fatkhan, E. Dinanto, A.S. Murtani // IOP Conference Series: Earth and Environmental Science. – 2023.

23. Ardebili P.N., Jozanikohan G., Moradzadeh A. Estimation of porosity and volume of shale using artificial intelligence, case study of Kashafrud Gas Reservoir, NE Iran // *J Petrol Explor Prod Technol.* – 2023.
24. Integrated image processing and computational techniques to characterize formation damage / C.P. Ezeakacha, A. Rabbani, S. Salehi, A. Ghalambor // *SPE International Conference and Exhibition on Formation Damage Control.* – 2018. – P. 157–168.
25. Petrophysics and mineral exploration: a workflow for data analysis and a new interpretation framework / M. Dentith, R.J. Enkin, W. Morris, C. Adams, B. Bourne // *Geophysical Prospecting.* – 2020. – Vol. 68. – P. 178–199. – DOI 10.1111/1365-2478.12882.
26. Pears G., Fullagar P., Andrews P. 3D Gravity modelling and interpretation for the 1:250,000 Boulia map sheet, Queensland // *ASEG Extended Abstracts.* – 2001. – Vol. 1. – P. 1–4.
27. Petrophysical properties (density and magnetization) of rocks from the suhbaatar-Ulaanbaatar-dalandzadgad geophysical profile in Mongolia and their implications / T. Yang, J. Gao, Z. Gu, B. Dagva, T. Tserenpil // *The Scientific World Journal.* – 2013. – P. 1–12.
28. Chandler V.W., Lively R.S. Density, magnetic susceptibility, and natural remanent magnetization of rocks in Minnesota: an mgs rock properties database // *Minnesota Geological Survey.* Retrieved from the University of Minnesota digital conservancy. – 2011.
29. Henkel H. Studies of density and magnetic properties of rocks from Northern Sweden // *Pure and Applied Geophysics.* – 2011. – Vol. 114. – P. 235–249.
30. Petrophysical constraints on gravity/magnetic interpretation in Israel / M. Rybakov, V. Goldshmidt, Y. Rotshtein, L. Fleischer // *Leading Edge.* – 1999. – Vol. 18. – P. 269–272.
31. Плотность распределения фильтрующих поровых каналов пластов коллекторов Западной Сибири / Р.Т. Ахметов, Л.С. Кулешова, Р.У. Рабаев, В.В.

Мухаметшин, А.М. Маляренко, Д.И. Кобища, Д.И. Ахметшина // SOCAR Proceedings. – 2021. – № 2. – С. 221–228.

32. Pore-throat structure characteristics and its impact on the porosity and permeability relationship of carboniferous carbonate reservoirs in eastern edge of Pre-Caspian Basin / L.I. Weiqiang, M.U. Longxin, Z.H. Lun, L.I. Jianxin, W.A. Shuqin, F.A.N. Zifei, S.U.N. Meng // Petroleum Exploration and Development. – 2020. – Vol. 47. – No. 5. – P. 1027–1041.

33. Grain shape effects on permeability, formation factor, and capillary pressure from pore-scale modeling / T. Torskaya, V. Shabro, C. Torres-Verdín, R. Salazar-Tio, A. Revil // Transport in Porous Media. – 2014. – Vol. 102. – No. 1. – P. 71–90.

34. Ахметов Р.Т. Гантельная модель пустотного пространства природных резервуаров нефти и газа // Геология, геофизика и разработка нефтяных и газовых месторождений. – 2011. – № 5. – С. 31–35.

35. Количественная оценка гидравлической извилистости коллекторов нефти и газа Западной Сибири на основе капилляриметрических исследований / Р.Т. Ахметов, А.М. Маляренко, Л.С. Кулешова, В.В. Мухаметшин, А.Р. Сафиуллина // Научные труды НИПИ Нефтегаз ГНКАР. – 2021. – № 2. – С. 77–84.

36. Choi C.S., Lee Y.K., Song J.J. Equivalent pore channel model for fluid flow in rock based on microscale X-ray CT imaging // Materials. – 2020. – Vol. 13. – No. 11. – P. 2619.

37. Tavanaei A., Salehi S. Pore, throat, and grain detection for rock SEM images using DigitalWatershed image segmentation algorithm // Journal of Porous Media. – 2015. – Vol. 18. – No. 5. – P. 1–27.

38. Permeability upscaling for carbonates from the pore scale by use of multiscale X-ray-CT images / A. Dehghan Khalili, J.-Y.-Y. Arns, F. Hussain, Y. Cinar, W.V.V. Pinczewski, C.H.H. Arns // SPE Reservoir Evaluation & Engineering. – 2013. – Vol. 16. – No. 4. – P. 353–368. – DOI 10.2118/152640-PA.

39. A novel optimization method for geological drilling vertical well / Y. Zhou, X. Chen, M. Wu, W. Cao // *Information Sciences*. – 2023. – Vol. 634. – P. 550–563. DOI: 10.1016/j.ins.2023.03.082.
40. Zhong R., Salehi C., Johnson R. Machine learning for drilling applications: a review // *Journal of Natural Gas Science and Engineering*. – 2022. – Vol. 108. – P. 104807. DOI: 10.1016/j.jngse.2022.104807.
41. Islam M.R., Hossain M.E. Chapter 3 – Advances in directional drilling / *Drilling Engineering. Towards Achieving Total Sustainability. Sustainable Oil and Gas Development Series*. – 2021. – P. 179–316. DOI: 10.1016/B978-0-12-820193-0.00003-4
42. Arps J.J. Analysis of decline curves // *Transactions of the AIME*. – 1945. – Vol. 160. – № 1. – P. 228–247. DOI: 10.2118/945228-G.
43. Dynamic oil and gas production optimization via explicit reservoir simulation / D.I. Gerogiorgis, M. Georgiadis, G. Bowen, C.C. Pantelides, E.N. Pistikopoulos // *Computer Aided Chemical Engineering* / Eds. W. Marquardt, C. Pantelides. – 2006. – Vol. 21. – P. 179–184. DOI: 10.1016/S1570-7946(06)80043-X
44. Geology-driven modeling: a new probabilistic approach for incorporating uncertain geological interpretations in 3D geological modeling / R.B. Madsen, A.-S. Høyer, L.T. Andersen, I. Møller, T.M. Hansen // *Engineering Geology*. – 2022. – Vol. 309. – P. 106833. DOI: 10.1016/j.enggeo.2022.106833.
45. Optimization of site exploration program based on coupled characterization of stratigraphic and geo-properties uncertainties / C. Zhao, W. Gong, C.H. Juang, H. Tang, X. Hu, L. Wang // *Engineering Geology*. – 2023. – Vol. 317. – P. 107081. DOI: 10.1016/j.enggeo.2023.107081.
46. Practical aspects of upscaling geocellular geological models for reservoir fluid flow simulations: a case study in integrating geology, geophysics, and petroleum engineering multiscale data from the Hunton group / B. Milad, S. Ghosh, R. Slatt, K. Marfurt, M. Fahes // *Energies*. – 2020. – Vol. 13. – № 7. – P. 1604. DOI: 10.3390/en13071604.

47. Геологическое строение и перспективы нефтегазоносности юряхского горизонта Среднеботуобинского месторождения / П.А. Оленич, И.А. Бухарова, М.С. Новикова, Г.О. Хорольский, А.С. Чиргун // Экспозиция Нефть Газ. – 2021. – № 6. – С. 58–61. DOI: 10.24412/2076-6785-2021-6-58-61.

48. Пономаренко А.С. Геология залежей карбонатных коллекторов непско-ботуобинской антеклизы // Вестник евразийской науки. – 2020. – № 6. – С. 1–9. URL: <https://cyberleninka.ru/article/n/geologiya-zalezhey-karbonatnyh-kollektorov-nepskobotuobinskoj-anteklizy> (дата обращения: 03.12.2024).

49. A review of machine learning applications to geophysical logging inversion of unconventional gas reservoir parameters / Z. Wang, Y. Cai, D. Liu, J. Lu, F. Qiu, J. Hu, Z. Li, R.P. Gamage // Earth-Science Reviews. – 2024. – Vol. 258. – P. 104969. DOI: 10.1016/j.earscirev.2024.104969.

50. Efficiency analysis of 30-stage fracturing in a horizontal well to oil rims based on through-barrier diagnostics / V. Nagimov, V. Virt, V. Kosolapov, D. Bakhitov, Y. Maslennikova, L. Spirina, I. Shigapov // SPE Russian Petroleum Technology Conference. – Moscow, Russia, October 2019. – P. 196834. DOI: 10.2118/196834-MS.

51. Peaceman D.W. Interpretation of well-block pressures in numerical reservoir simulation (includes associated paper 6988) // SPE Journal. – 1978. – Vol. 18. – No. 3. – P. 183–194. – DOI 10.2118/6893-PA.

52. Геофизические исследования скважин: учебное пособие / Национальный исследовательский Томский политехнический университет (ТПУ); сост. В.П. Меркулов. – Томск: Изд-во ТПУ, 2008. – 139 с.

53. Mahmood H.A., Al-Fatlawi O. Well placement optimization: a review // AIP Conference Proceedings. – AIP Publishing, 2022. – Vol. 2443. – № 1. DOI: 10.1063/5.0091904

54. Optimization of design variables and control rules in field development under uncertainty: A case of intelligent wells and CO<sub>2</sub> water alternating gas injection / A. Mirzaei-Paiaman, S.M.G. Santos, D.J. Schiozer // Geoenergy Science and Engineering. – 2023. – Vol. 227. – P. 211854. DOI: 10.1016/j.geoen.2023.211854.

55. Forouzanfar F., Reynolds A.C. Well-placement optimization using a derivative-free method // *Journal of Petroleum Science and Engineering*. – 2013. – Vol. 109. – P. 96–116. – DOI 10.1016/j.petrol.2013.07.009.

56. Andriana M., Anggono A.H. Project investment analysis on new oil and gas field development (M-X) at Pt. PTM // *European Journal of Business and Management Research*. – 2023. – Vol. 8. – № 4. – P. 168–172. DOI: 10.24018/ejbmr.2023.8.4.2001.

57. Mutruc C. Probabilistic evaluation of the net present value of an oil and gas project through Monte Carlo simulation. Diss. – Torino, 2018. – 108 p.

58. Bruyelle J., Guérillot D. Well placement optimization with an artificial intelligence method applied to Brugge field // *SPE Gas & Oil Technology Showcase and Conference*. – Dubai, UAE, October 2019. – P. D021S010R004. DOI: 10.2118/198656-MS.

59. Alrashdi Z., Sayyafzadeh M. Evolution strategy algorithm in well placement, trajectory, control and joint optimisation // *Journal of Petroleum Science and Engineering*. – 2019. – Vol. 177. – P. 1042–1058. DOI: 10.1016/j.petrol.2019.02.047.

60. Томский К.О., Иванова М.С. Оптимизация расположения многозабойной скважины в тонкой нефтяной оторочке, осложненной наличием обширной газовой шапки // *Записки Горного института*. – 2024. – Т. 265. – С. 140–146.

61. Zhang R., Chen H. Robust waterflood optimization under geological uncertainties using streamline-based well pair efficiencies and assimilated models // *Geoenergy Science and Engineering*. – 2023. – Vol. 231. – P. 212309. DOI: 10.1016/j.geoen.2023.212309.

62. Проблемы освоения тонких нефтяных оторочек газоконденсатных залежей Восточной Сибири (на примере ботуобинской залежи Чайнинского НГКМ) / С.В. Буракова, Д.В. Изюмченко, И.И. Минаков, В.А. Истомина, Е.Л. Кумейко // *Вести газовой науки*. – 2013. – № 5 (16). – С. 124–133. URL: <https://cyberleninka.ru/article/n/problemyosvoeniya-tonkih-neftyanyh-otorochek->

gazokondensatnyh-zalezhey-vostochnoy-sibiri-na-primere-botuobinskoj-zalezhi (дата обращения: 21.11.2024).

63. Мулявин С.Ф., Курамшин Р.М., Лапердин А.Н. Методические рекомендации по расчету коэффициента охвата для систем разработки скважинами сложной архитектуры // Недропользование XXI век. – 2012. – № 5. – С. 32–39.

64. Постников А.В., Постникова О.В., Оленова К.Ю., Хасанов И.И. и др. Новые методические аспекты литологических исследований пород баженовской свиты // Нефтяное хозяйство. – 2015. – № 10. – С. 23–27.

65. Хасанов И.И. Анализ цветности пород по цифровым изображениям керна // Геология нефти и газа. – 2014. – № 5. – С. 33–39.

66. 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. – V. 2015. – P.1 – 5.

67. Патент США №US8416413B2, 09.04.2013. Products and methods for identifying rock samples / Ellington W.E., Moore J.C., Smith M.A. [и др.].

68. Патент США №US2017286802, 2017. Automated core description / Mezghani M.M., Shammari S.H., Anifowose F.A.

69. Введение в TensorFlow // TensorFlow – URL: <https://www.tensorflow.org/learn?hl=ru> (дата обращения: 06.10.2023).

70. Keras. Get Started // Keras – URL: <https://keras.io/> (дата обращения: 06.10.2023).

71. Pillow (PIL Fork) 10.4.0 documentation // pillow, 2024 – URL: <https://pillow.readthedocs.io/en/stable/> (дата обращения: 03.10.2023).

72. NumPy 1.26.0 released // NumPy, 2024 – URL: <https://numpy.org/> (дата обращения: 03.10.2023).

73. 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).

74. OpenCV. Modules // Open-Source Computer Vision – URL: <https://docs.opencv.org/4.x/> (дата обращения: 27.09.2023).

75. 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](https://proproprogs.ru/neural_network/dropout-metod-borby-s-pereobucheniem-neyronnoy-seti) (дата обращения: 24.09.2023).
76. Tremeau A., Borel N. A region growing and merging algorithm to color segmentation // *Pattern Recognit.* – 1997. – V. 30. – № 7. – P. 1191–1203. – DOI: 10.1016/S0031-3203(96)00147-1.
77. Chaurasia A., Culurciello E. LinkNet: Exploiting encoder representations for efficient semantic segmentation // *2017 IEEE Visual Communications and Image Processing (VCIP)*. – 2017. – P. 1–4. – DOI: 10.1109/VCIP.2017.8305148.
78. Bach-Cuadra M., Duay V., Thiran J.P.H. Atlas-based Segmentation // *Handbook of Biomedical Imaging: Methodologies and Clinical Research*. – 2015. – P. 221–244. – DOI: 10.1007/978-0-387-09749-7\_12.
79. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. Lecture Notes in Computer Science*. – 2015. – P. 234–241. – DOI: 10.1007/978-3-319-24574-4\_28.
80. He K., Gkioxari G., Dollar P., Girshick R. Mask R-CNN // *Proc. IEEE Int. Conf. on Computer Vision (ICCV)*. – 2017.
81. Chen L.-C., Papandreou G., Kokkinos I., Murphy K., Yuille A.L. DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs // *IEEE Trans. Pattern Anal. Mach. Intell.* – 2018. – V. 40. – № 4. – P. 834–848. – DOI: 10.1109/TPAMI.2017.2699184.
82. Chen L.C., Zhu Y., Papandreou G., Schroff F., Adam H. Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation // *Lecture Notes in Computer Science*. – 2018. – V. 11211. – P. 833–851. – DOI: 10.1007/978-3-030-01234-2\_49.
83. ResNet: «остаточные» CNN для классификации изображений // *ResNet* – URL: <https://neurohive.io/ru/vidy-nejrosetej/resnet-34-50-101/> (дата обращения: 20.06.2025).

84. Zhou Z., Rahman Siddiquee M.M., Tajbakhsh N., Liang J. UNet++: A Nested U-Net Architecture for Medical Image Segmentation // Lecture Notes in Computer Science. – 2018. – V. 11045. – P. 3–11. – DOI: 10.1007/978-3-030-00889-5\_1.

85. Cubuk E.D., Zoph B., Mane D., Vasudevan V., Le Q.V. AutoAugment: Learning Augmentation Strategies From Data // Proc. IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). – 2019. – P. 113–123. – DOI 10.1109/CVPR.2019.00020.

86. Денисов В. И. Исследование эффективности архитектур нейронных сетей для сегментации раздробленных образцов керна / В.И. Денисов, Е.А. Андренкова // Молодежь и современные информационные технологии: сб. тр. XXII Междунар. науч.-практ. конф. студентов, аспирантов и молодых ученых, Томск, 2025 г. Томск: Национальный исследовательский Томский политехнический университет. – 2025. – С. 550-555.

87. Денисов В.И. Модификация архитектуры сети U-Net для задач классификации и сегментации образцов пород / В.И. Денисов, А.И. Кочегуров, Н.Е. Семенченко, Е.А. Андренкова // Системы анализа и обработки данных. – 2025. – № 2 (98). – С.33–52.

88. Denisov V. I. Hybrid Algorithm for Real-Time Data Forecasting with Density-Based Clustering and Penalty Splines/ E. A. Kochegurova, V. I. Denisov, M. V. Galkina // International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM 2024). Proceedings. – 2024. – P. 1039–1044.

89. Denisov V. I. Modification of U-Net Network Architecture for Core Samples Analysis Automation / V. I. Denisov, A. I. Kochegurov, N. E. Semenchenko // International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM 2025): Proceedings. – 2025. – P. 863–868.

90. Денисов В. И. Применение средств машинного обучения для исследования образцов керна / В.И. Денисов, Е.А. Задорожных // Молодежь и современные информационные технологии: сб. тр. XXI Междунар. науч.-практ.

конф. студентов, аспирантов и молодых ученых, Томск, 15–18 апр. 2024 г. Томск: Национальный исследовательский Томский политехнический университет. – 2024. – С. 158–163.

91. Денисов В. И. Сегментация образцов пород на основе модифицированной архитектуры сети U-Net / В.И. Денисов, Н.Е. Семенченко // Молодежь и современные информационные технологии: сб. тр. XXII Междунар. науч.-практ. конф. студентов, аспирантов и молодых ученых, Томск, 2025 г. Томск: Национальный исследовательский Томский политехнический университет. – 2025. – С. 599-604.

92. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition // Proc. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR). – 2016. – P. 770–778. – DOI: 10.1109/CVPR.2016.90.

93. Tan M., Le Q.V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks // Proc. 36th International Conference on Machine Learning (ICML). – 2019. – P. 10691–10700.

94. Dosovitskiy A. et al. An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale // Int. Conf. on Learning Representations (ICLR). – 2021.

95. Lin T.-Y., Dollar P., Girshick R., He K., Hariharan B., Belongie S. Feature Pyramid Networks for Object Detection // Proc. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR). – 2017. – P. 936–944. – DOI: 10.1109/CVPR.2017.106.

96. Selvaraju R.R., Cogswell M., Das A., Vedantam R., Parikh D., Batra D. Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization // 2017 IEEE International Conference on Computer Vision (ICCV). – 2017. – P. 618–626. – DOI: 10.1109/ICCV.2017.74.

97. Chattopadhyay A., Sarkar A., Howlader P., Balasubramanian V.N. Grad-CAM++: Generalized Gradient-Based Visual Explanations for Deep Convolutional Networks // 2018 IEEE Winter Conference on Applications of Computer Vision (WACV). – 2018. – P. 839–847. – DOI: 10.1109/WACV.2018.00097.

98. Денисов В.И. Гибридный алгоритм оценки нефтенасыщенности керна по макрофотографиям породы в видимом и ультрафиолетовом свете / А.И. Кочегуров, В.И. Денисов, Н.Е. Семенченко, Е.А. Андренкова // Известия Томского политехнического университета. Инжиниринг георесурсов. – 2025. – Т. 336. – № 10. – С. 28–37.

99. Денисов В. И. Новый этап развития цифровизации документооборота – работа с проектной документацией в формате XM / В.И. Денисов, О.Н. Луценко, В.В. Лапковская, Н.М. Тепляков // Известия Томского политехнического университета. Промышленная кибернетика. – 2023. – Т. 1. – № 1. – С. 17–23.

100. Симкин А.В. Подход к комплексному применению методологий систематизации требований // Прикладная информатика. – 2013. – № 3. – С. 60–75.

101. Apache Software Foundation. Apache Kafka Documentation: [Электронный ресурс]. – 2025. – URL: <https://kafka.apache.org/documentation/> (дата обращения: 08.01.2026).

102. MinIO, Inc. MinIO Documentation: [Электронный ресурс]. – 2025. – URL: <https://min.io/docs/minio/linux/index.html> (дата обращения: 08.01.2026).

103. MongoDB, Inc. MongoDB Manual: [Электронный ресурс]. – 2025. – URL: <https://www.mongodb.com/docs/manual/> (дата обращения: 08.01.2026).

104. Redis Ltd. Redis Documentation: [Электронный ресурс]. – 2025. – URL: <https://redis.io/docs/> (дата обращения: 08.01.2026).

105. Amazon Web Services. Amazon Simple Storage Service (Amazon S3) User Guide: [Электронный ресурс]. – 2025. – URL: <https://docs.aws.amazon.com/AmazonS3/latest/userguide/Welcome.html> (дата обращения: 08.01.2026).

106. C4 Model. C4 model for visualising software architecture: [Электронный ресурс]. – 2024. – URL: <https://c4model.com> (дата обращения: 08.01.2026).

107. Python Software Foundation. Python 3.12 Documentation: [Электронный ресурс]. – 2023. – URL: <https://docs.python.org/3.12/> (дата обращения: 08.01.2026).

108. Microsoft. ASP.NET Core documentation: [Электронный ресурс]. – 2025. – URL: <https://learn.microsoft.com/aspnet/core/> (дата обращения: 08.01.2026).
109. Microsoft. .NET 8 documentation: [Электронный ресурс]. – 2023. – URL: <https://learn.microsoft.com/dotnet/> (дата обращения: 08.01.2026).
110. Google. Angular documentation: [Электронный ресурс]. – 2024. – URL: <https://angular.dev> (дата обращения: 08.01.2026).
111. OpenCV. OpenCV Documentation: [Электронный ресурс]. – 2025. – URL: <https://docs.opencv.org/4.x/> (дата обращения: 08.01.2026).
112. Li M., Lv T., Chen J., Cui L., Lu Y., Florencio D., Zhang C., Li Z., Wei F. TrOCR: Transformer-Based Optical Character Recognition with Pre-trained Models // Proceedings of the AAAI Conference on Artificial Intelligence. 2023. Vol. 37, no. 11. P. 13094–13102. DOI: 10.1609/aaai.v37i11.26538.

## Приложение А

### Псевдокод алгоритма онлайн аугментации

#### Вход:

$D$  – обучающая выборка из  $N$  пар  $(X_j, M_j)$ , где  $X_j$  – изображение,  $M_j$  – маска,  $j = 1..N$ ;  $N_{\text{эпох}}$  – число эпох обучения;  $B$  – размер пакета данных;  $P$  – набор допустимых преобразований и их параметры;  $s_0$  – начальное значение генератора случайных чисел (при необходимости воспроизводимости);  $W$  – начальные параметры модели.

#### Выход:

$W$  – параметры обученной модели.

#### Псевдокод:

Если задано  $s_0$ , инициализировать генератор случайных чисел значением  $s_0$ .

Для  $i$  от 1 до  $N_{\text{эпох}}$ :

$S$  – пустой массив пар {изображение, маска}

Для  $j$  от 1 до  $N$ :

$(X_j, M_j)$  принимают значения пары  $D[j]$

добавить  $(X_j, M_j)$  в  $S$

выбрать преобразование  $R$  из  $P$  и его параметры по правилам  $P$

$(X_j^{\wedge}, M_j^{\wedge})$  получают значения результата применения  $R$  к  $(X_j, M_j)$

добавить  $(X_j^{\wedge}, M_j^{\wedge})$  в  $S$

Пока число элементов  $S$  не меньше  $B$ :

    выполнить шаг обучения на первых  $B$  парах из  $S$  и обновить  $W$

    удалить эти  $B$  пар из  $S$

Если число элементов  $S$  больше 0:

    выполнить шаг обучения на  $S$  и обновить  $W$

$S$  становится пустым списком

Вернуть  $W$

## Приложение Б

### Постобработка результатов OCR распознавания

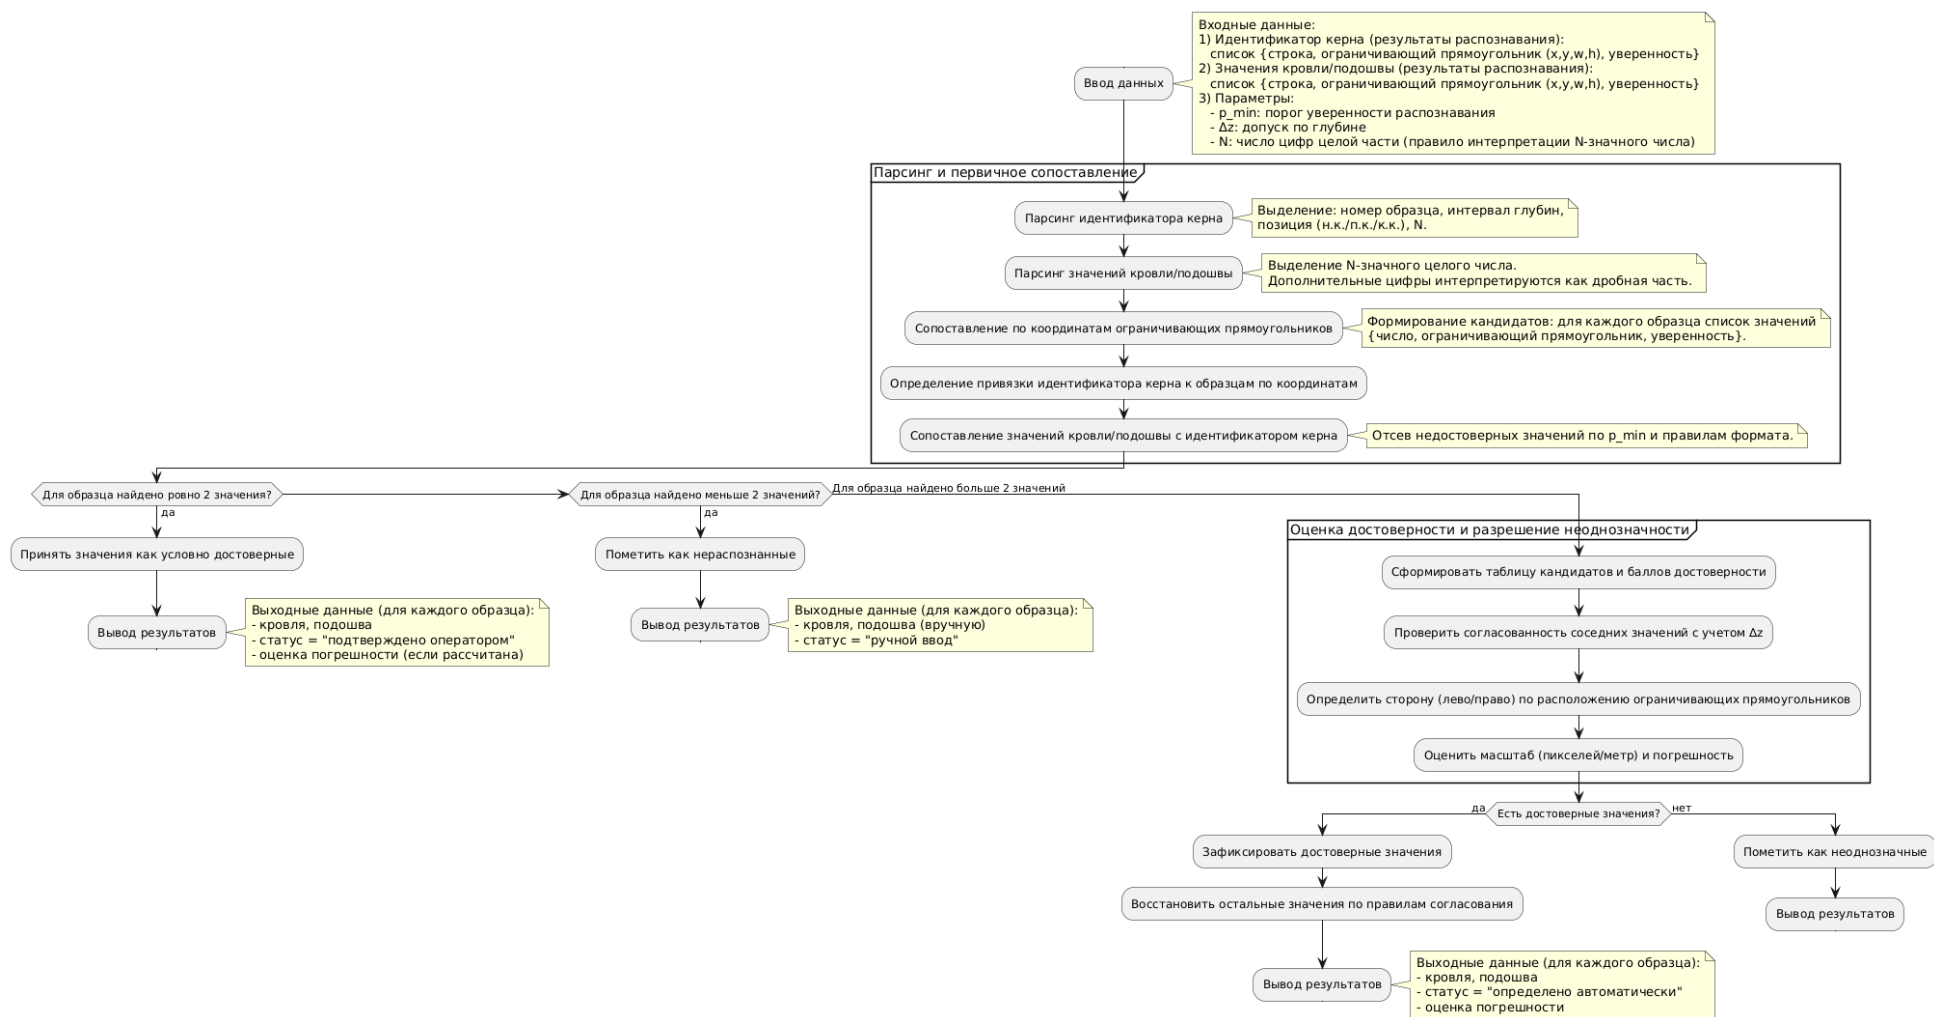


Рисунок В.1– Алгоритм постобработки результатов распознавания отметок кровли и подошвы

## **Приложение В**

### **Акты внедрения результатов диссертационной работы**



Ministry of Science and Higher Education of the Russian Federation  
Federal State Autonomous Educational Institution of Higher Education  
«National Research Tomsk Polytechnic University» (TPU)  
30, Lenin ave., Tomsk, 634050, Russia  
Tel. +7-3822-606333, +7-3822-701779,  
Fax +7-3822-606444, https://tpu.ru  
ОКПО (National Classification of Enterprises and Organizations): 02069303,  
Company Number: 1027000890168,  
VAT/KPP (Code of Reason for Registration)  
7018007264/701701001, BIC 016902004

Министерство науки и высшего образования Российской Федерации  
федеральное государственное автономное образовательное  
учреждение высшего образования  
«Национальный исследовательский  
Томский политехнический университет» (ТПУ)  
Ленина, пр., д. 30, г. Томск, 634050, Россия  
тел.: +7-3822-606333, +7-3822-701779,  
факс: +7-3822-606444, https://tpu.ru  
ОКПО 02069303, ОГРН 1027000890168,  
ИНН/КПП 7018007264/701701001, БИК 016902004

№ \_\_\_\_\_  
на № \_\_\_\_\_ от \_\_\_\_\_

«УТВЕРЖДАЮ»  
Проректор по образовательной  
деятельности  
М.А. Соловьев  
2026 г.

#### АКТ

о внедрении результатов диссертационной работы Денисова Владислава Игоревича на тему «Анализ изображений керна в видимом и ультрафиолетовом диапазонах для оценки нефтенасыщенности пород и хранения цифровых данных на основе методов машинного обучения» в учебный процесс Отделения информационных технологий Инженерной школы информационных технологий и робототехники Томского политехнического университета.

Комиссия в составе председателя – директора ИШИТР, к.т.н. А.С. Фадеева и ее членов: и.о. руководителя ОИТ ИШИТР, к.т.н. В.С. Хорева, к.т.н., доцента ОИТ Е.С. Чердынцев, к.т.н., доцента ОИТ А.В. Погребной, составили настоящий акт о внедрении в учебный процесс ОИТ следующих результатов диссертационной работы Денисова В.И.:

- гибридная архитектура модифицированной сети U-Net, которая отличается от классической добавлением промежуточных связей между слоями декодера, введением остаточных блоков, заменой свертки на глубинно-разделяемую и внедрением механизмов внимания;
- алгоритм обучения с механизмами ранней остановки и сохранением лучших весов, что гарантирует воспроизводимость результатов и стабильность эксперимента.

Представленные решения демонстрируют, как модификация уже существующей и зарекомендовавшей архитектуры сети может заметно повысить качество классификации и семантической сегментации при решении задач в конкретной предметной области. Благодаря этим улучшениям модель позволяет получать более точные результаты и работает эффективнее, чем классическая U-Net.

Результаты диссертационной работы используются для подготовки бакалавров по направлению 01.03.02 «Прикладная математика и информатика» при проведении лабораторных работ по дисциплине «Компьютерный анализ данных, а также при выполнении исследовательских, курсовых и выпускных квалификационных работ студентов.

Председатель

Члены комиссии

А.С. Фадеев  
В.С. Хорев  
Е.С. Чердынцев  
А.В. Погребной

## НАУЧНО-АНАЛИТИЧЕСКИЙ ЦЕНТР



Общество с ограниченной ответственностью

634029, г. Томск, ул. Советская, 26, e-mail: [nedraGA@mail.tomsknet.ru](mailto:nedraGA@mail.tomsknet.ru), (382-2) 53-48-65

## АКТ

об использовании результатов диссертационной работы Денисова Владислава Игоревича на тему: «Анализ изображений керна в видимом и ультрафиолетовом диапазонах для оценки нефтенасыщенности пород и хранения цифровых данных на основе методов машинного обучения» по специальности 2.3.1 Системный анализ, управление и обработка информации, статистика в компании Общество с ограниченной ответственностью Научно-аналитический центр «Недра»

В диссертации Денисова В.И. предложена и апробирована технология исследования изображений керна в дневном и ультрафиолетовом диапазонах для оценки нефтенасыщенности пород на основе применения методов машинного обучения. Для этих целей была построена гибридная архитектура нейронной сети и разработан алгоритм оценки нефтенасыщенности пород на основе анализа сегментированных изображений керна.

Цель данной диссертационной работы - улучшить инструмент анализа неопределённостей при оценке характера продуктивности (нефть, газ, битум) перспективных пластов нефтяных и газовых месторождений

В исследовании предлагается подход к прогнозированию нефтегазоносности резервуаров на основе применения методов машинного обучения, который может компенсировать неопределённости оценок традиционных моделей, основанных на базе комплексных сейсмических данных, цифровых геолого-гидродинамических моделей, РИГИС и результатов лабораторных исследований керна. Технические ограничения, связанные с исследованиями скважин, высокая петрофизическая неоднородность резервуаров часто приводят к получению недостоверных данных о характере насыщения и, как следствие, к пропуску продуктивных интервалов, что негативно отражается на динамике добычи.

Предложенная методика и разработанные В.И. Денисовым алгоритмические и программные инструменты для дополнительного исследования керна позволяют автоматизировать процесс и повысить качество оценок при прогнозе характера насыщения резервуаров. Методика прошла адаптацию и испытания на реальных проектах, реализуемых в исследовательской и производственной деятельности ООО НАЦ «Недра». Экономический эффект будет достигаться за счет снижения экономических и временных затрат, направленных на дополнительные исследования в скважинах, для повышения нефтеотдачи пластовых систем нефтяных месторождений

Главный геофизик  
ООО НАЦ «Недра»



Г.А. Сысолятина