

**Федеральное государственное автономное образовательное  
учреждение высшего образования «Российский государственный  
университет нефти и газа (национальный исследовательский университет)  
имени И.М. Губкина»**

*На правах рукописи*

**Галкина Алёна Владимировна**

**РАЗВИТИЕ МОДЕЛЕЙ ГЕОНАВИГАЦИИ СКВАЖИН НА ОСНОВЕ  
ДИНАМИЧЕСКОГО АНАЛИЗА ДАННЫХ КАРОТАЖА И МЕТОДОВ  
КОМПЬЮТЕРНОГО ЗРЕНИЯ**

Специальность 1.2.2 – Математическое моделирование, численные методы и  
комплексы программ

**ДИССЕРТАЦИЯ**

на соискание ученой степени  
кандидата технических наук

Научный руководитель:  
доктор технических наук  
профессор  
Каневская Регина Дмитриевна

Москва – 2026

## ОГЛАВЛЕНИЕ

|                                                                                                                          |    |
|--------------------------------------------------------------------------------------------------------------------------|----|
| ВВЕДЕНИЕ.....                                                                                                            | 4  |
| ГЛАВА 1. ЗАДАЧИ АВТОМАТИЗАЦИИ ГЕОНАВИГАЦИИ СКВАЖИН И ПУТИ ИХ РЕШЕНИЯ .....                                               | 11 |
| 1.1. Основные подходы к автоматизации процесса геонавигации .....                                                        | 11 |
| 1.2. Современные подходы к решению задачи геологической корреляции .....                                                 | 15 |
| 1.2.1. Постановка задачи геологической корреляции .....                                                                  | 15 |
| 1.2.2. Кросс-корреляция.....                                                                                             | 18 |
| 1.2.3. Экспертные системы.....                                                                                           | 19 |
| 1.2.4. Триангуляция .....                                                                                                | 20 |
| 1.2.5. Динамическое программирование .....                                                                               | 21 |
| 1.2.6. Машинное обучение .....                                                                                           | 29 |
| 1.2.7. Глубокое обучение .....                                                                                           | 32 |
| 1.3. Методы анализа азимутального плотностного каротажа.....                                                             | 38 |
| 1.3.1. Постановка задачи.....                                                                                            | 38 |
| 1.3.2. Типовые подзадачи компьютерного зрения в анализе имиджей.....                                                     | 40 |
| 1.3.3. Классические алгоритмы обработки изображений .....                                                                | 41 |
| 1.3.4. Геометрические и частотные методы.....                                                                            | 43 |
| 1.3.5. Методы машинного и глубокого обучения .....                                                                       | 46 |
| 1.3.6. Подходы к оценке качества и обучению моделей в задачах анализа геофизических изображений.....                     | 53 |
| Основные выводы к главе 1.....                                                                                           | 57 |
| ГЛАВА 2. МЕТОДИКА УТОЧНЕНИЯ ПОЛОЖЕНИЯ КРОВЛИ ЦЕЛЕВОГО ПЛАСТА ПРИ БУРЕНИИ ТРАНСПОРТНОЙ СЕКЦИИ СКВАЖИНЫ .....              | 59 |
| 2.1. Постановка задачи.....                                                                                              | 59 |
| 2.2. Алгоритм динамической трансформации временной шкалы (DTW).....                                                      | 61 |
| 2.3. Модификации классического подхода для решаемой задачи .....                                                         | 62 |
| 2.4. Итеративный прогноз кровли целевого пласта.....                                                                     | 70 |
| Основные выводы к главе 2.....                                                                                           | 71 |
| ГЛАВА 3. МАТЕМАТИЧЕСКАЯ МОДЕЛЬ ГРАНИЦ ПРОДУКТИВНОГО ПЛАСТА В ОКРЕСТНОСТИ ГОРИЗОНТАЛЬНОГО СТВОЛА БУРЯЩЕЙСЯ СКВАЖИНЫ ..... | 73 |

|                                                                                                |            |
|------------------------------------------------------------------------------------------------|------------|
| 3.1. Алгоритм автоматического анализа сходимости гамма-каротажа при геонавигации.....          | 73         |
| 3.2. Анализ данных азимутального плотностного каротажа .....                                   | 76         |
| 3.2.1. Постановка задачи.....                                                                  | 76         |
| 3.2.2. Формализация задачи в терминах анализа изображений.....                                 | 77         |
| 3.2.3. Обучение сверточного автоэнкодера для восстановления структуры изображения.....         | 79         |
| 3.2.4. Контурная фильтрация .....                                                              | 86         |
| 3.2.5. Обучение сверточного бинарного классификатора .....                                     | 89         |
| Основные выводы к главе 3.....                                                                 | 92         |
| <b>ГЛАВА 4. АПРОБАЦИЯ И ТЕСТИРОВАНИЕ РАЗРАБОТАННЫХ РЕШЕНИЙ</b>                                 | <b>94</b>  |
| 4.1. Апробация методики уточнения положения кровли целевого пласта в транспортной секции ..... | 95         |
| 4.1.1. Общая логика апробации и критерии успешности .....                                      | 95         |
| 4.1.2. Пример работы методики.....                                                             | 96         |
| 4.2. Тестирование алгоритма анализа перезаписи гамма-каротажа .....                            | 100        |
| 4.2.1. Постановка эксперимента .....                                                           | 101        |
| 4.2.2. Общая оценка результатов .....                                                          | 101        |
| 4.2.3. Примеры работы алгоритма.....                                                           | 102        |
| 4.3. Результаты апробации модели распознавания границ при бурении горизонтальной секции.....   | 107        |
| 4.3.1. Постановка эксперимента и особенности данных .....                                      | 107        |
| 4.3.2. Обучение и применение автоэнкодера.....                                                 | 108        |
| 4.3.3. Качество классификатора как отдельного компонента .....                                 | 110        |
| 4.3.4. Анализ работы последовательности обработки данных.....                                  | 114        |
| 4.3.5. Определение угла залегания структуры по выделенным «улыбкам» ...                        | 116        |
| 4.3.6. Обсуждение результатов и практическая применимость .....                                | 117        |
| <b>ЗАКЛЮЧЕНИЕ</b> .....                                                                        | <b>120</b> |
| <b>СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ</b> .....                                                  | <b>122</b> |
| <b>ПРИЛОЖЕНИЕ А. ТЕРМИНЫ И ОПРЕДЕЛЕНИЯ</b> .....                                               | <b>134</b> |
| <b>ПРИЛОЖЕНИЕ Б. ПЕРЕЧЕНЬ УСЛОВНЫХ ОБОЗНАЧЕНИЙ И СОКРАЩЕНИЙ</b><br>.....                       | <b>135</b> |

## ВВЕДЕНИЕ

**Актуальность исследования.** Современная практика разработки месторождений характеризуется устойчивым ростом доли наклонно-направленных и, особенно, горизонтальных скважин, что связано с их очевидными технологическими и экономическими преимуществами [1, 2]: повышение коэффициента извлечения за счёт охвата ранее не вовлечённых в разработку зон, возможность бурения в акваториях и на шельфе, эффективность при малой мощности и низкой проницаемости, меньшая чувствительность к подошвенным водам и снижение экологической нагрузки на промысловую территорию. В то же время усложнение траектории и условий бурения порождает ряд критичных недостатков: спускоподъёмные операции становятся технологически сложнее из-за сильного искривления ствола, повышается стоимость работ, а проведение геофизических исследований осложняется анизотропией среды, проблемами центрирования приборов и неоднородностями бурового раствора. Эти факторы повышают цену ошибок и ужесточают требования к геологическому сопровождению бурения (геонавигации) в реальном времени [3, 4, 5].

Геонавигация представляет собой преднамеренное изменение положения ствола в пласте на основе анализа навигационной, геологической и геофизической информации, поступающей в процессе бурения, с целью максимального охвата целевого интервала и минимизации неэффективной проходки [6]. В производственной практике центров геологического сопровождения одновременно могут находиться в активной фазе десятки скважин, каждая из которых сопровождается непрерывным потоком разнородных данных каротажа в процессе бурения (LWD). Рост числа горизонтальных стволов, а также усложнение геологического строения (малая мощность пластов, литологические замещения, выклинивания, переслаивания, тектонические нарушения) значительно повышают нагрузку на инженеров-геонавигаторов и увеличивают риск субъективных и запаздывающих решений.

Ключевые риски геонавигации связаны как с геологическими неопределённостями, так и с инструментальными и измерительными

ограничениями [7]. К геологическим факторам относятся неопределённости в положении кровли и подошвы продуктивного пласта, вариативность мощности, неопределённость углов залегания, а также наличие разломов, выклиниваний и линз. Инструментальные факторы включают погрешности глубинной привязки, инклинометрии, ошибки измерения длины бурильной колонны, влияние температурных деформаций и отклонения центрации приборов. Совокупность указанных факторов приводит к повышенному риску выхода ствола за пределы допустимого коридора проводки и потере контакта с продуктивным интервалом, что непосредственно отражается на технико-экономических показателях бурения.

Содержательно активная фаза геонавигационного сопровождения включает две принципиально различные стадии: бурение транспортной секции и бурение горизонтальной секции. В транспортной секции ключевой задачей является корректная «посадка» на кровлю целевого пласта. При этом прогноз положения кровли затруднён как неопределённостью геологической модели, так и вариативностью мощностей и углов залегания в районе цели. Исторически задачи корреляции каротажей и геологической увязки вдоль ствола решались вручную с использованием операций растяжения и сжатия каротажных кривых и сопоставления с опорными разрезами [8, 9]. Такой подход трудоёмок, подвержен субъективизму и, как правило, приводит к упрощённым линейным представлениям пластов, плохо учитывающим локальные деформации и разрывные нарушения.

В горизонтальной секции эффективность бурения определяется долей ствола, проведённой по продуктивным отложениям, и способностью оперативно распознавать изменения литологии вокруг долота. Существенную роль при этом играют азимутальные каротажные изображения, в которых вследствие цилиндрической геометрии скважины при развёртке на плоскость формируются характерные синусоидальные структуры («улыбки»), соответствующие пересечению геологических границ при движении по или против напластования [10, 11, 12]. Корректная и своевременная интерпретация этих паттернов позволяет восстанавливать угол падения структуры и определять направление изменения литологии, что имеет решающее значение для принятия геонавигационных

решений. Однако высокий уровень шума, неоднородность данных и значительный объём информации затрудняют ручную фильтрацию и классификацию таких признаков в реальном времени.

В последние годы активно развивается концепция «интеллектуальной геонавигационной системы», объединяющей геологические модели, физику пласта и методы оптимизации с алгоритмами машинного обучения и анализа данных [13, 14]. В рамках данной концепции предполагается предварительное обучение моделей на исторических данных с последующим использованием быстрых аппроксимаций в реальном времени, что позволяет существенно сократить задержки в принятии решений. Тем не менее, переход от научно-методических разработок к промышленным внедрениям ограничивается дефицитом качественно размеченных данных, высокой вариативностью геологических условий и ограниченным числом воспроизводимых программных решений, пригодных для интеграции в существующие производственные регламенты.

Таким образом, актуальной является задача разработки воспроизводимых, устойчивых к шуму и неполноте данных методов автоматизированного анализа каротажной информации при геонавигации. Практические требования промышленного бурения – высокая скорость реакции, интерпретируемость результатов, устойчивость к неопределённостям и снижение субъективного фактора обуславливают необходимость комплексного подхода, включающего автоматизированное уточнение положения кровли целевого интервала в транспортной секции и автоматическое выделение и интерпретацию азимутальных структур в горизонтальной секции. Решение указанных задач непосредственно направлено на снижение риска выхода из продуктивной части пласта, повышение доли эффективной проводки и уменьшение непроизводительных затрат при строительстве скважин.

Итак, с учётом роста сложности объектов и объёма данных, высокой стоимости ошибок и ограничений традиционных ручных процедур интерпретации, разработка математически обоснованных, устойчивых к шумам и пригодных для реального времени методов анализа данных при геонавигации является актуальной

научно-технической задачей. Особую значимость приобретают решения, которые используют информацию о ранее пробуренных скважинах для повышения точности прогнозов и технологически масштабируются до уровня программных комплексов сопровождения бурения.

**Целью диссертационной работы** является разработка математических моделей, методик и компонентов программного комплекса для уточнения положения бурящейся скважины относительно границ пласта в процессе геологического сопровождения бурения.

Для достижения цели поставлены и решены следующие **задачи**:

1. Проведён аналитический обзор и систематизация подходов к интерпретации каротажных данных в процессе геологического сопровождения бурения; выявлены существующие проблемы и возможные пути их решения.
2. Разработана методика уточнения положения кровли целевого пласта при бурении транспортной секции скважины.
3. Разработана математическая модель границ продуктивного пласта в окрестности горизонтального ствола бурящейся скважины, основанная на азимутальных каротажных изображениях.
4. Создан алгоритм для автоматического поиска сдвига перезаписи гамма-каротажа при переходе от транспортной к горизонтальной секции.
5. Разработанные решения реализованы в виде интегрируемых программных модулей, которые совместимы с производственным процессом геонавигации и независимы от конкретной приборной конфигурации.
6. Проведена валидация на реальных данных, подтвердившая применимость решений в условиях непрерывного геологического сопровождения бурения в режиме реального времени.

В исследовании используются следующие **методы**: методы оптимизации, методы динамического программирования, статистические методы, методы глубокого обучения и методы компьютерного зрения. Для программной реализации используется язык программирования Python.

**Основные положения, выносимые на защиту:**

1. Новая методика уточнения положения кровли целевого пласта при бурении транспортной секции скважины, основанная на модифицированном DTW-сопоставлении интервалов каротажа в опорных и разбуриваемой скважинах, которая обеспечивает вход в целевой пласт с плановыми параметрами.
2. Математическая модель распознавания геологических границ по данным азимутального каротажа, основанная на комплексном использовании методов классического компьютерного зрения и сверточных нейронных сетей, которая позволяет получать геологически интерпретируемые оценки наличия и параметров границ пласта, что обеспечивает возможность оперативной корректировки траектории скважины.
3. Алгоритм для автоматического поиска сдвига перезаписи гамма-каротажа при переходе от транспортной к горизонтальной секции, основанный на скользящем корреляционном сопоставлении, который обеспечивает оперативное выявление и оценку сдвига перезаписи.
4. Комплекс программных модулей, реализующий разработанные модели и алгоритмы, валидация и апробация которого на реальных данных подтверждают работоспособность и применимость предложенных решений для геологического сопровождения бурения.

**Научная новизна** диссертации заключается в следующем:

1. Предложен новый модифицированный алгоритм DTW (Dynamic Time Warping, динамической трансформации временной шкалы) для сопоставления интервалов каротажа при геонавигации в реальном времени и последующего уточнения расстояния до кровли целевого пласта при бурении транспортной секции горизонтальной скважины, что обеспечивает более устойчивую и физически согласованную привязку интервалов каротажа по сравнению с классическим DTW.
2. Создана новая математическая модель распознавания геологических границ пласта на азимутальных изображениях в окрестности горизонтального ствола бурящейся скважины с учётом цилиндрической геометрии; на её

основе реализована вычислительная последовательность обработки данных, объединяющая методы компьютерного зрения и сверточные нейронные сети, что обеспечивает устойчивую работу при ограниченной разметке и прямую геологическую интерпретацию.

3. Впервые сформулирован и реализован алгоритм для автоматического поиска сдвига перезаписи гамма-каротажа при переходе от транспортной к горизонтальной секции.

**Практическая значимость и внедрение.** Работа предлагает целостный, воспроизводимый комплекс решений для обеих критичных фаз проводки – транспортной и горизонтальной секций, опирающийся на сопоставление последовательностей, предобработку изображений и специализированные нейросетевые компоненты. Комплексность подхода и его адаптируемость к качеству входных данных обеспечивают технологическую применимость и масштабируемость на разные месторождения и приборы, обеспечивая повышение эффективности проводки горизонтальных скважин в режиме реального времени. Реализация предложенных решений позволяет: снижать риск выхода из целевого пласта за счёт прогноза положения кровли целевого интервала до входа в горизонтальный участок; ускорять и унифицировать обработку азимутальных изображений благодаря автоматической детекции «улыбок». Разработанные решения и программные модули внедрены в ПО для геонавигации и используются в режиме реального времени; описанные принципы и параметры работы модулей согласуются с ограничениями отраслевых регламентов. По результатам разработки технологии был получен патент «Способ бурения горизонтальной скважины».

**Апробация работы.** Материалы исследования докладывались и обсуждались на следующих научно-практических конференциях: «Нефтяная столица» (г. Нижневартовск, 2020 г.), «Нефть и газ – 2021» (г. Москва, Российский государственный университет нефти и газа (НИУ) имени И.М. Губкина, 2021 г.), «Цифровые технологии в добыче углеводородов: от моделей к практике» (г. Уфа, 2021 г.), Кустовых и Межрегиональных научно-технических конференциях молодых специалистов ПАО «НК «Роснефть» (г. Москва, 2020–2022 гг.),

«Информационные технологии для наук о Земле и цифровизация в геологии и горнодобывающей промышленности» (г. Владивосток, 2022 г.), «Геобайкал-2022» (г. Иркутск, 2023 г.).

**Личный вклад.** Основные результаты диссертации получены автором самостоятельно. Постановка задач и обсуждение результатов осуществлялись вместе с научным руководителем. Автором лично разработаны методика для прогноза положения кровли; математическая модель анализа азимутальных данных; алгоритм контроля перезаписей каротажа, а также их программная реализация, выполнены подготовка данных, вычислительные эксперименты и анализ результатов.

**Публикации.** По теме диссертации опубликовано 7 печатных работ, в том числе 3 в изданиях, рекомендуемых ВАК РФ, и 1 патент на изобретение.

## ГЛАВА 1. ЗАДАЧИ АВТОМАТИЗАЦИИ ГЕОНАВИГАЦИИ СКВАЖИН И ПУТИ ИХ РЕШЕНИЯ

### 1.1. Основные подходы к автоматизации процесса геонавигации

#### *Геонавигация как итеративный процесс интерпретации*

Традиционный процесс геонавигации основан на непрерывном сопоставлении данных, поступающих в процессе бурения, с информацией по опорным скважинам и априорной геологической моделью. Инженер-геонавигатор вручную корректирует положение структурных поверхностей, подбирая углы падения и смещения пластов таким образом, чтобы каротажные кривые, приведённые к сопоставимому виду, согласовывались между собой. В отечественных работах геонавигация рассматривается как самостоятельное научно-практическое направление, развитие которого связано с цифровизацией интерпретации, совершенствованием LWD/MWD-технологий и автоматизированной поддержкой принятия решений [15, 16].

Процесс геонавигации носит итеративный характер, требует постоянного анализа разнородных данных и существенно зависит от опыта специалиста. При одновременном сопровождении нескольких скважин возрастает нагрузка на инженера и усиливается влияние субъективного фактора. Кроме того, геонавигация рассматривается как элемент комплексного сопровождения строительства скважин, в рамках которого данные каротажа, параметры бурения и обновляемая геологическая модель используются для оперативной корректировки решений [17, 18]. В совокупности это обуславливает потребность в автоматизированных методах, направленных на ускорение интерпретации, повышение воспроизводимости решений и снижение риска ошибок.

#### *Автоматизация интерпретации каротажных данных*

Одним из первых направлений автоматизации стало применение методов машинного обучения для корреляции каротажных данных с опорными скважинами. В работе [19] предложены алгоритмы, автоматически подбирающие

геологическую модель, наилучшим образом согласующуюся с измерениями в горизонтальной скважине и данными соседних стволов с учётом геологических ограничений.

Авторы используют нейросетевые модели для формирования компактных представлений интервалов каротажа, что позволяет автоматизировать процесс сопоставления сигналов. Модель обучается на искажённых версиях каротажных данных, имитирующих реальные условия бурения. Эксперименты показывают высокую степень совпадения автоматических интерпретаций с результатами ручной геонавигации (рисунок 1), однако при сложной геологии с выраженными латеральными изменениями качество решений снижается, что подчёркивает ограниченность универсальных сквозных подходов.



Рисунок 1. Сравнение результатов ручной и автоматической настройки [19].

### *Интеллектуальные геонавигационные платформы*

Дальнейшее развитие автоматизации связано с формированием концепции интеллектуальных геонавигационных систем, объединяющих геологию, физику пласта, методы оптимизации и машинного обучения. В работе [20] предложена архитектура платформы, включающая синтетическое моделирование каротажа,

автоматическую корреляцию измерений и выбор оптимального целевого интервала бурения.

В более широком контексте цифровизации строительства скважин методы искусственного интеллекта применяются также для анализа геолого-технологических данных, прогнозирования осложнений, поддержки бурения и снижения рисков при работе с данными реального времени [21, 22, 23, 24]. Эти работы демонстрируют общий переход отрасли к интеллектуальным системам поддержки решений, для которых критичны качество входных данных, воспроизводимость алгоритмов и возможность работы в режиме реального времени.

В ряде исследований нейронные сети используются для аппроксимации прямых и обратных геофизических задач, что позволяет существенно сократить время расчётов после этапа обучения [25]. Отдельные работы предлагают интеграцию генеративных моделей и нейросетевых аппроксиматоров прямых задач для оценки геологической неопределённости в реальном времени [26]. Несмотря на перспективность, практическое внедрение таких платформ ограничено высокой вычислительной сложностью, необходимостью больших обучающих выборок и сложностью валидации результатов в условиях реального бурения.

#### *Автономные системы бурения*

Отдельную группу работ составляют исследования, ориентированные на автономное принятие решений при бурении. В работе [27] геонавигация рассматривается как часть задачи оптимального управления буровой системой, формализованной в виде марковского процесса принятия решений. Подобные подходы направлены на оптимизацию управляющих воздействий с учётом рисков и неопределённостей.

Несмотря на методологическую близость, данные решения выходят за рамки задач интерпретации геофизических данных и относятся к более высокому уровню

автоматизации, где интерпретация служит лишь одним из входных компонентов системы управления.

### *Геонавигация как задача обратного моделирования*

Альтернативный подход к автоматизации геонавигации основан на формализации интерпретации как геофизической обратной задачи. В работе [28] возможные интерпретации параметризуются и оцениваются по степени согласованности с измерениями, при этом в реальном времени отслеживается несколько правдоподобных решений с последующим подавлением нереалистичных интерпретаций. Такой подход позволяет учитывать неоднозначность и повышает воспроизводимость результатов (рисунок 2).




Рисунок 2. Стратиграфическая тепловая карта несоответствия интерпретации специалиста (зелёный) и автоматической интерпретации (красный) [28].

Сравнительный анализ автоматизированных и ручных интерпретаций, проведённый в работе [29], показал высокую степень совпадения по ключевым геонавигационным показателям при существенном снижении операционной нагрузки на специалистов. В других исследованиях используются методы

машинного обучения для прогнозирования литологических характеристик и ожидаемых свойств разреза на основе данных соседних скважин [30, 31], а также для оперативного выявления изменения типа породы при направленном бурении по данным ГТИ (геолого-технологические исследования) [32].

Отдельное значение имеет программная реализация таких решений: специализированные веб-ориентированные комплексы позволяют объединять визуализацию, вычислительные модули и обработку данных в процессе бурения [33].

Анализ существующих работ показывает, что автоматизация геонавигации развивается по нескольким взаимосвязанным направлениям: автоматизация интерпретации каротажных данных, разработка интеллектуальных геонавигационных платформ и создание автономных систем управления бурением. При этом наиболее устойчивыми и практически применимыми являются модульные решения, автоматизирующие отдельные ключевые этапы интерпретации, а не полностью сквозные (end-to-end) системы.

В настоящей работе выбран именно такой модульный подход. Разработаны методы и модели для автоматизации ключевых этапов геонавигации в транспортной и горизонтальной секциях скважины, ориентированные на практическое применение, устойчивость к шуму и геологической неоднородности, а также на интеграцию в единую программную систему поддержки геонавигационных решений.

## **1.2. Современные подходы к решению задачи геологической корреляции**

### **1.2.1. Постановка задачи геологической корреляции**

Корреляция разрезов скважин является фундаментальным элементом при изучении внутренней структуры отложений и моделировании любых геологических объектов. Внутрипластовая корреляция разрезов скважин представляет собой важный инструмент для петрофизической интерпретации, позволяющий более точно оценить свойства и состав горных пород,

минимизировать неопределенность геологического моделирования, принять более обоснованные решения при планировании бурения, оптимизации добычи и повысить эффективность разработки месторождения. На основе результатов корреляции строятся все последующие модели свойств пласта.

Задачей геологической корреляции является выделение в разрезе и прослеживание по площади реперов, т. е. пластов, литологически отличающихся от выше- и нижележащих отложений. Такой пласт имеет характерную, ярко выраженную на диаграммах ГИС реперную границу. Основная сложность геологической корреляции заключается в том, что даже в расположенных вблизи скважинах геологическое строение может отличаться, один и тот же пласт в скважинах может иметь различную мощность, что затрудняет процесс корреляции.

Одним из применений геологической корреляции является сопровождение бурения транспортной секции разбуриваемой скважины. Геологическая корреляция позволяет корректировать траекторию разбуриваемой скважины при приближении к кровле целевого пласта (интервала) и сохранять плановые значения углов в точке входа в пласт с целью обеспечения оптимального входа в пласт и бурения горизонтальной секции ствола скважины.

В настоящее время геологическая корреляция пластов в процессе бурения чаще всего осуществляется специалистами по геологическому сопровождению бурения вручную на основе их экспертного опыта. Однако традиционные ручные методы корреляции часто являются трудоемкими и требуют значительных временных затрат. В связи с этим за последние десятилетия предпринимались многочисленные попытки формализовать и автоматизировать процесс автокорреляции. Систематизация современных подходов к автоматической корреляции геологических разрезов скважин приведена в работе автора [34].

В общем виде задачу геологической корреляции каротажей можно сформулировать как задачу поиска соответствия между измерениями каротажа, зарегистрированными в различных скважинах, с сохранением их порядка вдоль глубины.

Пусть  $z_1, z_2, \dots, z_N$  – дискретные значения глубины вдоль ствола скважины, соответствующие точкам регистрации каротажных измерений. Каротажную кривую будем рассматривать как упорядоченную последовательность значений  $y = \{y_i\}_{i=1}^n$ , где  $y_i$  – измеренное значение каротажа на глубине  $z_i$ .

Пусть заданы две каротажные кривые  $y^{(1)} = (y_1^{(1)}, y_2^{(1)}, \dots, y_n^{(1)})$ ,  $y^{(2)} = (y_1^{(2)}, y_2^{(2)}, \dots, y_m^{(2)})$ , где  $y_i^{(1)}$  и  $y_j^{(2)}$  – значения одного и того же каротажного параметра, измеренные на различных глубинах в соответствующих скважинах,  $n, m \in \mathbb{N}$  – длины первой и второй каротажных последовательностей соответственно.

Корреляция заключается в построении отображения

$$\pi \subset \{1, \dots, n\} \times \{1, \dots, m\}, \quad (1.1)$$

задающего соответствие между элементами двух каротажных кривых и удовлетворяющего условию сохранения порядка индексов. При этом  $\pi$  рассматривается как упорядоченная последовательность пар индексов. Обозначим через  $\Pi$  множество всех допустимых соответствий  $\pi$ , определяемое выбранной моделью корреляции.

Качество соответствия  $\pi$  оценивается с помощью целевой функции

$$J(\pi) = \sum_{(i,j) \in \pi} f(y_i^{(1)}, y_j^{(2)}), \quad (1.2)$$

где  $f(\cdot, \cdot)$  – некоторая мера несходства между значениями каротажа.

Тогда задача корреляции формулируется как задача оптимизации:

$$\pi^* = \arg \min_{\pi \in \Pi} J(\pi). \quad (1.3)$$

В зависимости от выбранных ограничений на множество допустимых соответствий  $\Pi$ , формы функции несходства  $f$  и способа минимизации функционала  $J$ , данная общая постановка задачи геологической корреляции приводит к различным классам методов решения. В литературе, посвящённой корреляции каротажных данных, можно выделить несколько основных направлений, включая классические корреляционные методы, экспертные и эвристические системы, подходы, основанные на построении триангуляционных

сетей скважин, методы, использующие оптимизационные алгоритмы (в том числе динамическое программирование), а также современные модели машинного обучения и глубокие нейронные сети. Каждое из указанных направлений по-разному формализует допустимые соответствия между каротажными кривыми и предъявляет собственные требования к данным, вычислительным ресурсам и степени интерпретируемости результата.

### 1.2.2. Кросс-корреляция

Первые подходы к решению задачи автоматической корреляции каротажных кривых были основаны на вычислении кросс-корреляции [35]. В рамках общей постановки задачи такие методы предполагают, что соответствие между каротажными кривыми задаётся глобальным сдвигом вдоль глубины, то есть соответствие  $\pi$  имеет вид  $\pi = \{(i, i + m)\}$ , где  $m$  – фиксированный сдвиг.

Кросс-корреляция между двумя дискретными каротажными кривыми  $y^{(1)}, y^{(2)}$  определяется как функция сдвига  $m$ :

$$f_m = \sum_{n=m+1}^N y_n^{(1)} \cdot y_{n-m}^{(2)}, \quad (1.4)$$

где  $N$  – длина сопоставляемых каротажных последовательностей,  $m = \overline{0, N-1}$ .

Таким образом, корреляция устанавливается путем скольжения одного из рядов вдоль другого, при этом сдвиг происходит на один элемент последовательности за раз и на каждом шаге вычисляется коэффициент корреляции (например, Пирсона). Обычно можно получить много значимых корреляций, но в результате выбирается корреляция с максимальным значением. Методы кросс-корреляции можно рассматривать как частный случай общей постановки, в котором множество допустимых соответствий  $\pi$  ограничено линейным сдвигом, а минимизация функционала  $J(\pi)$  сводится к поиску оптимального значения параметра  $m$ . Среди преимуществ такого подхода стоит отметить инвариантность относительно операции умножения на константу или прибавления константы к одному из временных рядов. В то же время в случае приведения к одному масштабу

и единицам измерения, метод может дать высокий коэффициент сходимости для участка с явно выраженным изменением свойства и участка с незначительным изменением свойства (то же возрастание или форма, но другая амплитуда). Кроме того, метод чувствителен к выбросам и различному масштабу по оси времени (глубины).

Этот подход был улучшен с помощью преобразования Фурье [36] для вычисления корреляции в частотной области. Такое преобразование обычно применяется в цифровой обработке сигнала и раскладывает сигнал на синусоидальные составляющие с различными частотами. Частный случай – дискретное преобразование Фурье, применим, когда входные сигналы представляют собой дискретную функцию. Так,  $k$ -я составляющая сигнала в частотной области:

$$DFT(k) = \sum_{n=0}^{N-1} y_n \cdot e^{-\frac{2\pi i}{N}kn}, k = \overline{0, N-1}. \quad (1.5)$$

Среди преимуществ подхода с вычислением корреляций в частотной области стоит отметить более высокую степень распознавания сигналов в условиях зашумленности данных. Однако этот подход неприменим в случае переменной мощности пластов.

### 1.2.3. Экспертные системы

Следующим этапом в развитии подходов к автоматической корреляции стали экспертные системы [37, 38], основанные на множестве правил для вычисления корреляции на основе геологических условий, сейсмических данных, качества каротажа и т. д. Авторами исследования [38] была разработана система, состоящая из трёх компонентов: алгоритм динамического программирования для сопоставления каротажных кривых и поиска оптимального соответствия, набор правил для управления процессом корреляции и база данных, содержащая каротажные кривые и другие геологические и сейсмические данные. Авторы работы [39] одними из первых предложили полноценное коммерческое ПО «CORRELATOR» для автоматической корреляции каротажных кривых, которое

представляет собой интерактивную компьютерную программу, основанную на вычислении взвешенного коэффициента корреляции с использованием двух каротажных кривых по каждой скважине. В программе реализована экспертная система, которая позволяет выявлять несоответствующие корреляции в базе данных и сообщать о них пользователю.

В терминах общей постановки такие системы задают допустимое множество соответствий  $\pi$  неявно, через систему правил и ограничений, а функция несходства  $f$  и процедура минимизации  $J(\pi)$  управляются экспертной логикой. Главным преимуществом такого подхода является возможность учёта накопленного опыта и высокая интерпретируемость результатов корреляции. В то же время создание такой системы достаточно трудоемко поскольку необходимо составлять подробные базы правил, которые, в большинстве случаев, уникальны для каждого отдельного месторождения. Кроме того, воспроизведение логики экспертов хорошо работает в обычных сценариях, но является сложной задачей для крайних случаев, таких как замещения или выклинивания.

#### 1.2.4. Триангуляция

Среди российских исследований в области автоматической корреляции стоит отметить два решения, которые получили широкое признание и активно используются в практике: AutoCorr (РГУ нефти и газа) и DV Geo (Центральная геофизическая экспедиция). Оба подхода к автоматической корреляции основаны на построении триангуляционной сети скважин и расширяют общую постановку на многоскважинный случай, где оптимизируется согласованность соответствий  $\pi$  одновременно для множества пар скважин.

Идея подхода заключается в анализе пар скважин, которые располагаются на одном ребре графа, сформированного в результате триангуляции их расположения на плоскости. При перемещении по ребрам графа от одной скважины к другой, используя различные маршруты, можно столкнуться с различиями в результатах, что приводит к возникновению невязок. Эти невязки, по сути, являются

несоответствиями в данных, которые необходимо устранить для достижения согласованной модели.

Авторы системы AutoCorr [40] предлагают разделять результаты автоматической попарной корреляции скважин на простые и сложные участки, на которых наблюдаются значительные расхождения, при этом соответствующие ребра графа выделяются цветом на планшете, что позволяет геологу внести корректировки только в относительно небольшом числе случаев.

Авторы статьи [41] применяют метод, который схож с подходом И.С. Гутмана, однако акцент в их работе сделан на более сбалансированное взаимодействие автоматизированных и ручных процедур. В данном случае основное внимание уделяется корреляции протяженных интервалов скважин, которые могут варьироваться от 60 до 100 метров. Корреляция достигается путем смещения интервалов для максимального согласования в горизонтальном направлении. Автоматически можно рассчитать коррелированные поверхности, которые не представляют конкретный пласт, а лишь формальные горизонты. Преимущество метода заключается в отсутствии необходимости ручного вмешательства и в получении объективного набора геологических гипотез. Полученные формальные поверхности, несмотря на отсутствие ясного геологического смысла, используются для построения трехмерной геологической модели. Ручной этап корреляции выполняется внутри автоматической визуальной среды, что облегчает задание стратиграфических границ и повышает точность стратиграфического каркаса модели.

Несмотря на широкую распространенность и эффективность описанных подходов, они требуют вмешательства геолога и не являются полностью автоматизированными.

### **1.2.5. Динамическое программирование**

Большая группа решений задачи геологической корреляции основана на использовании алгоритмов динамического программирования, в частности алгоритма динамической трансформации временной шкалы (*DTW*) и его

модификаций. Данный подход позволяет находить оптимальное соответствие между элементами двух последовательностей, допускающими нелинейные деформации по оси глубины.

Алгоритм DTW решает задачу (1.3) при дополнительном ограничении на множество допустимых соответствий  $\Pi$ : на переходы между индексами вводится ограничение на монотонность, связность и сохранения порядка. В этом подходе на основе расстояний между элементами последовательностей определяется оптимальное соответствие среди допустимых путей. Стоимость такого соответствия определяется как [42]:

$$DTW(y^{(1)}, y^{(2)}) = \min_{\pi \in \Pi} \frac{1}{K} \sum_{k=1}^K d(y_{i_k}^{(1)}, y_{j_k}^{(2)}), \quad (1.6)$$

где  $\pi = \{(i_k, j_k)\}_{k=1}^K$  – путь выравнивания, а  $d(\cdot)$  – мера несходства. Пример работы алгоритма на синтетических данных приведён на рисунке 3.




Рисунок 3. Пример работы алгоритма DTW на синтетических данных.

Авторами статьи [43] предложен алгоритм динамической трансформации временной шкалы, который использует данные сразу по нескольким каротажам для корреляции пластов между скважинами. Алгоритм позволяет использовать до 20 каротажных кривых на скважину, взвешенных в зависимости от качества данных и геологической среды. Авторы отметили, что апробация предложенного подхода была успешно произведена в группе из 10 скважин с месторождения на побережье

Мексиканского залива США по данным гамма-излучения, нейтронной пористости, плотности, индукционного каротажа и др.

Поскольку непрерывность пластов может изменяться, например, из-за разломов, это может приводить к неправильной корреляции с помощью алгоритма DTW. Для минимизации этой неопределенности в работе [44] предлагают для каждой пары поверхностей, ограничивающих коррелируемый пласт, задавать диапазон поиска  $L$  в зависимости от толщины пласта. В классическом алгоритме DTW предполагается, что попарные расстояния вычисляются для всех элементов анализируемых последовательностей. Модификация, предлагаемая авторами, состоит в том, чтобы за пределами диапазона поиска расстояния между парами точек принять равными бесконечности:

$$d_{ij} = \begin{cases} d(y_i^{(1)}, y_j^{(2)}), & j \in [i - L, i + L], \\ \infty, & \text{иначе} \end{cases} \quad (1.7)$$

где  $L$  – заданный диапазон поиска. Авторы утверждают, что подобная модификация алгоритма значительно уменьшает вероятность неправильной корреляции по сравнению с результатами классического DTW.

Одно из предположений, которое делает классический DTW, заключается в том, что начало и конец последовательностей данных представляют собой истинное начало и конец одной и той же последовательности, т. е.  $w_1 = (1, 1)_1$ ,  $w_K = (n, m)_K$ . Однако в задачах геологической корреляции данные каротажа в скважинах относятся к различным диапазонам абсолютных глубин и не всегда охватывают одни и те же пласты, таким образом данные не полностью связаны друг с другом и чаще всего задача сводится к нахождению некоторого интервала каротажа из одной скважины  $y^{(1)}$  на всём каротаже  $y^{(2)}$  другой скважины и вместо глобального выравнивания двух последовательностей необходимо решать задачу поиска подпоследовательности в более длинной последовательности. Для реализации такого подхода авторы работы [45] предлагают использовать некоторый программный «трюк». Он состоит в том, чтобы добавить столбец в левую часть исходной локальной матрицы затрат, а затем заполнять его, вводя «нулевое» расстояние. Последующие шаги соответствуют

классическому алгоритму. Авторы работы [46] вводят модификацию алгоритма под названием Subsequence Dynamic Time Warping (SDTW), которая позволяет вместо одного оптимального решения, как в DTW, построить несколько оптимальных решений (рисунок 4). Для отсеивания нежизнеспособных решений в алгоритм могут быть добавлены дополнительные геологические ограничения, что является преимуществом использования SDTW. В терминах общей постановки переход к Subsequence DTW означает ослабление ограничений на начало и конец соответствия  $\pi$ , что позволяет искать оптимальное соответствие между заданным интервалом одной кривой и подпоследовательностью другой.




Рисунок 4. Пример результатов вычислений алгоритма SDTW [46].

В большинстве работ в качестве входных данных рассматриваются данные ГИС, однако в одной из работ [47] было предложено использовать для корреляции значения химических концентраций наиболее важных породообразующих химических элементов, полученных с помощью зондов спектроскопии нейтронного захвата (ECS) и гамма-спектрометрии естественного излучения (NGS, HNGS). Авторы объясняют свой выбор тем, что данные гамма-каротажа, удельное сопротивление и другие данные ГИС так же чувствительны к флюидам (буровой раствор), как и к горной породе. Предлагаемый подход был реализован в программном продукте Well2Well (Schlumberger-Doll Research). Элементы,

которые считаются более важными с геологической точки зрения, могут быть включены в анализ и взвешены по значимости в соответствии с предпочтениями пользователей, в то время как менее важные микроэлементы, такие как торий и уран, которые являются основными компонентами гамма-излучения, могут быть исключены. Автоматическая корреляция в предлагаемом подходе осуществляется на основе алгоритма DTW. Авторы отмечают, что тестирование решения на нескольких наборах данных с месторождений США и Ближнего Востока показало достаточно точную корреляцию между скважинами, расположенными на расстоянии нескольких сотен метров.

В качестве дальнейших шагов по развитию систем автоматической корреляции исследователи начали рассматривать подходы, основанные на комплексировании нескольких методов анализа данных. Например, в работе [48] предлагается комплексная система автоматической корреляции скважин (АКС), которая реализована в качестве плагина к программному комплексу геолого-геофизического моделирования Petrel (Schlumberger). Автором также проведён сравнительный анализ алгоритмов для задачи распознавания отбивки пласта на неизвестной скважине, среди которых кросс-корреляция, алгоритм множественного выравнивания ДНК, DTW и искусственная нейронная сеть, а также несколько алгоритмов для уточнения области поиска отбивки с использованием геометрии простираия пластов, сейсмической интерпретации, исследований керна, сегментации каротажных кривых. Также автор предлагает некоторые модификации алгоритма DTW для решения задачи геологической корреляции. Для поиска оптимального пути автор предлагает использовать алгоритм  $A^*$  – алгоритм поиска по первому наилучшему совпадению в графе, который находит маршрут с наименьшей стоимостью от одной вершины к другой. Система была протестирована на реальных данных с месторождения нефти и газа Мексиканского залива и результаты показали высокую точность.

В методе, предложенном авторами статьи [49] для создания каротажей спектральных трендов (Detrend Error log, DTEL и Integrand Detrend Error log, INDTEL) используется непрерывное вейвлет-преобразование (CWT). На

следующем этапе для автоматической корреляции этих каротажей применяется алгоритм DTW.

В работе [50] предложен метод автоматической корреляции разреза, основанный на алгоритмах кластерного анализа, методе главных компонент и DTW. Использование методов главных компонент и кластерного анализа позволяет упорядочить данные скважин по близости в смысле некоторой нормы, что, в свою очередь, способствует более эффективной корреляции разреза с применением алгоритма DTW. Применение кластеризации дает возможность объединить скважины в заданное число кластеров на основе близости нормы, что потенциально упрощает корреляцию разрезов внутри каждой из групп. В результате использования алгоритма DTW отметки на коррелируемой скважине устанавливаются в соответствии с данными наиболее близкой по расстоянию опорной скважины. Авторы отмечают, что по их опыту метод DTW может допускать ошибки при детальной корреляции, однако он достаточно точно справляется с корреляцией устойчивых пластов большой толщины. Апробация алгоритма была успешно проведена по данным гамма-каротажа, ННКт и БК на более чем 300 скважинах месторождений ПАО «НК «Роснефть». С точки зрения точности предложенного подхода, оцененная ошибка корреляции в 94% случаев составила менее 1 метра. Несмотря на высокую точность предложенного подхода, корреляция будет различаться в зависимости от числа кластеров, которое предполагается заданным экспертно. Также важно отметить, что расстановка отметок по корреляции с некоторой группой скважин в окрестности рассматриваемой скважины может показать более точную оценку и снизить влияние зашумленности в данных ближайшей скважины. Сходная прикладная схема автоматизации межскважинной корреляции с использованием предварительной обработки каротажных кривых, выбора эталонных скважин, кластеризации и последующего DTW-сопоставления рассмотрена в работе [51], где согласованность результатов с экспертной интерпретацией составила 85%.

Поскольку корреляцию каротажных данных можно рассматривать как процесс нахождения соответствия между глубинами в различных скважинах,

каждый набор таких соответствующих друг другу глубин часто соответствует одному геологическому периоду, в течение которого формировались отложения со схожими свойствами. Авторы статьи [52] предлагают рассматривать корреляцию каротажа скважин как задачу сопоставления глубины каротажа каждой скважины с геологическим временем (Relative Geologic Time, RGT). Предлагаемая авторами модификация метода DTW состоит в том, чтобы строить матрицу попарных расстояний в новой системе координат, и таким образом гарантировать, что все возможные пути трансформации имеют одинаковую длину за счёт уменьшения смещения, зависящего от длины пути. На рисунке 5 показаны два возможных пути трансформации  $a$  и  $b$  в системе координат  $ij$ . Каждая точка на пути представляет собой пару соответствующих глубин в каротажах. Путь  $a$  содержит меньше пар  $(i, j)$ , чем путь  $b$ , и поэтому, вероятно, будет иметь меньшую накопленную стоимость пути просто потому, что он короче.




Рисунок 5. Предлагаемый поворот системы координат [52].

Авторы предлагают искать оптимальный путь в новых координатах  $kl$ :

$$\begin{cases} k = j + i \\ l = j - i \end{cases} \Leftrightarrow \begin{cases} i = \frac{k - l}{2} \\ j = \frac{k + l}{2} \end{cases} \quad (1.8)$$

где координата  $k$  отражает глубину, а  $l$  – лаг, т. е. разницу глубин. Таким образом, элемент локальной матрицы расстояний в новой системе координат можно представить в виде  $d_{ij} = d\left(y_{\frac{k-l}{2}}^{(1)}, y_{\frac{k+l}{2}}^{(1)}\right)$ . Сдвиги по глубине, необходимые для

получения RGT, вычисляются путем преобразования результатов большого числа попарных корреляций DTW в задачу оптимизации методом наименьших квадратов, которая в работе решается с помощью метода сопряженных градиентов. Переход от глубины к относительному геологическому времени можно рассматривать как изменение параметризации соответствия  $\pi$ , при котором оптимизация функционала  $J$  проводится в новой системе координат. Авторы утверждают, что этот метод обеспечивает глобально оптимальное выравнивание всех каротажных кривых и в то же время устойчив к большим погрешностям измерений, свойственным данным гамма-каротажа.

На основе подхода, предложенного [52], авторы работы [53] используют идею перехода от глубин к относительному геологическому времени (RGT) для создания трехмерно согласованной корреляционной структуры. Полученная в результате хроностратиграфическая диаграмма дает представление об общей стратиграфии и ее изменчивости, а структура корреляции значительно отличается от того, что можно было бы получить при корреляции, основанной на литологическом сходстве двух каротажей. Для создания геологически понятных каротажных разрезов авторы используют непрерывное вейвлет-преобразование для определения стратиграфических единиц определенного масштаба в одной скважине и последующего распространения этих границ на все остальные скважины. Этот подход показал свою эффективность на примере почти 700 скважин Пермского бассейна (Западный Техас, США). Авторы отмечают, что такой подход можно использовать для быстрого построения трехмерных стратиграфических моделей для больших сегментов осадочных бассейнов, где имеется достаточно данных каротажа.

В работе [54] предложен подход к последовательной корреляции множества скважин на основе DTW. Порядок сопоставления задаётся с использованием 3D-сейсмических атрибутов, позволяющих учитывать геологическую непрерывность разреза. Для уменьшения накопления ошибок при переходе от одной скважины к другой используются ранее скоррелированные скважины и рассчитывается показатель достоверности корреляции. Подход эффективен для массовой

межскважинной корреляции, но требует качественного набора скважинных и сейсмических данных, что ограничивает его применение в задаче оперативного уточнения положения пласта при бурении

Таким образом, во многих работах алгоритм DTW был реализован как для попарной, так и для многоскважинной геологической корреляции и показал сравнительно высокое качество корреляции. Однако стоит отметить, что результат DTW зависит от формы кривой и не учитывает хронологические взаимосвязи в условиях осадконакопления. Тем не менее, алгоритм позволяет учитывать неравномерность протекания процессов формирования геологических объектов, являясь инвариантным, как относительно сдвига, так и относительно наличия сжатий и растяжений. Даже при наличии пропущенных интервалов алгоритм обнаруживает соответствие при условии наличия достаточного количества других сегментов для согласования, хотя для некоторых последовательностей наблюдается тенденция слишком сжимать или растягивать интервалы. Данная проблема рассматривалась в работе [55], где была предложена модификация метода – Derivative Dynamic Time Warping (DDTW), состоящая в использовании первой производной от последовательностей, чтобы ориентироваться не на сами значения, а на форму кривой, что помогает учитывать локальные тренды в данных и, например, не сопоставлять восходящий тренд с нисходящим.

#### **1.2.6. Машинное обучение**

Благодаря быстрому развитию вычислительных технологий методы машинного обучения стали более мощными. Эти методы позволяют извлекать из данных очень сложные закономерности, что делает их применимыми для задач автоматической геологической корреляции. Методы машинного обучения формируют соответствие между каротажными кривыми неявно, через обучение отображения, аппроксимирующего либо соответствие  $\pi$ , либо параметры геологических маркеров, которые затем используются для построения соответствия.

Один из первых нейросетевых подходов к задаче корреляции пластов был предложен в работе [56] (рисунок 6). Подход позволяет извлекать наиболее

характерные геологические признаки из каждого слоя для дальнейшего определения местоположения похожих маркеров в каротажных кривых других скважин. Авторы статьи [57] также предложили использовать полносвязную нейронную сеть для задачи сопоставления глубин, но уже в качестве входных данных использовали несколько каротажей по каждой скважине.




Рисунок 6. Нейронная сеть прямого распространения [56].

В работе [58] авторы на примере Правдинского месторождения предложили подход для выделения пластов при автокорреляции добывающих скважин по расставленным маркерам пластов на разведочных скважинах. В основе предлагаемого подхода к автокорреляции лежит другая нейросетевая архитектура – самоорганизующиеся карты Кохонена (рисунок 7), которые обучаются без учителя, подстраиваясь под закономерности входных данных.




Рисунок 7. Структура сети Кохонена.

В качестве входных данных для работы алгоритма используются данные ГИС: метод самопроизвольной поляризации, индукционный каротаж и гамма-каротаж. Каждому из методов ГИС приписывается свой весовой коэффициент. По монолитным пластам с субпараллельным залеганием алгоритм демонстрирует 80% совпадение, по наименее изученным пластам ачимовской толщи результаты автокорреляции показали совпадение 67% с расставленными вручную маркерами.

В статье [59] для автокорреляции предлагается использовать комплексный метод, который позволяет помимо данных ГИС учитывать результаты сейсмических исследований, в частности структурные карты трендов. Для автокорреляции в качестве базового алгоритма авторы также предлагают использовать самоорганизующиеся карты Кохонена. Результаты автокорреляции, полученные с помощью модели, сопоставляются с направлениями карт трендов и при превышении граничных значений отклонений алгоритм запускается повторно с целью минимизации отклонений результатов работы алгоритма от трендов до заданных значений. Данная методика является гибкой, поскольку позволяет задавать веса входных данных, граничных значений допустимых отклонений от трендов, но в то же время по этой же причине не является полностью автоматизированной и требует предварительной настройки или в процессе корреляции.

### 1.2.7. Глубокое обучение

В последнее время для решения задачи геологической корреляции внедряется всё больше современных моделей нейронных сетей: сверточные (CNN), рекуррентные (RNN), с механизмом внимания (attention-based). В терминах общей постановки глубокие нейронные сети обучаются аппроксимировать либо функцию несходства  $f$ , либо непосредственно отображение между глубинами различных скважин, минуя явное построение соответствия  $\pi$ .

Авторы статьи [60] используют двухэтапный подход к разработке решения для автокорреляции: на первом этапе решается задача нахождения маркера на данных каротажа как задача детекции границ (бинарная классификация) с помощью глубокой нейронной сети (рисунок 8). На втором этапе признаки, полученные с помощью бинарного классификатора для определения границ, используются для классификации выделенных границ по нескольким классам.




Рисунок 8. Подготовка данных для определения границ пластов и их последующей классификации [60].

В исследовании [61] представлен автоматизированный стратиграфический коррелятор на основе архитектуры сети двунаправленной долговременной памяти (BiLSTM), поскольку осадконакопление по своей природе является последовательным процессом, а рекуррентные сети умеют работать с такими

последовательностями. Для стратиграфической интерпретации данных каротажа используется CNN (рисунок 9).




Рисунок 9. Архитектура нейронной сети BiLSTM [61].

В предлагаемом подходе с помощью машинного обучения прогнозируются как зоны (задача многоклассовой классификации/сегментации), так и кровли и подошвы интервалов (задача обнаружения границ). В качестве входных данных для обучения моделей используется гамма-каротаж, удельное электрическое сопротивление и др. Эта методология была опробована на одном из крупнейших нефтяных месторождений Ближнего Востока, при этом средняя абсолютная погрешность интерпретации границ пластов после постобработки составляет около 3 метров для всех проанализированных скважин, что обеспечило точность порядка 90 % для тестовой выборки и свидетельствует об эффективности предлагаемого подхода.

В работе [62] предлагается модель автоэнкодера, основанная на архитектуре SegNet. Чтобы добиться более точной корреляции, в качестве признаков помимо данных каротажей используются данные их вейвлет-преобразования. Применение этого метода к скважинам на нефтяном месторождении Шенгли (Shengli Oilfield) показало, что такой подход позволяет получать точную стратиграфическую

корреляцию значительно эффективнее по сравнению с традиционным ручным методом.

В статье [63] авторы предлагают архитектуру сети, основанную на механизме внимания или «attention» (Attention Based Dense Network, ASDNet), для стратиграфической корреляции каротажных данных. Для реализации предложенной модели авторы сначала используют механизм внимания для обработки входных каротажных данных, который может эффективно генерировать взвешенные каротажные данные для дальнейшего извлечения признаков с помощью CNN. Впоследствии на извлеченных признаках обучается модель архитектуры DenseNet, которая эффективно борется с проблемой затухания градиента (рисунок 10). Оценка качества полученной модели производилась на основе данных каротажа скважин на северо-западе Китая. Результаты демонстрируют, что предлагаемая ASDNet обеспечивает более высокую точность прогнозирования для автоматической стратиграфической корреляции каротажных данных скважин, чем архитектуры UNet и SegNet.




Рисунок 10. Упрощённая архитектура предлагаемой нейронной сети ASDNet [63].

Авторы исследования [64] использовали одномерные сверточные нейронные сети (1D-CNN) для решения задачи сопоставления глубин каротажей. Были обучены семь отдельных моделей CNN для каждого из каротажей (гамма-излучение, удельное сопротивление, Р-волны и S-волны, плотность, нейтронный и фотоэлектрический коэффициенты (PEF) для оценки несоответствий глубины между исходными данными каротажа во время бурения (logging-while-drilling, LWD) и данными электрического каротажа на кабеле (electrical-wireline-logging, EWL). В работе используется позднее слияние модальностей: оценки, полученные

по разным типам каротажных данных, объединяются на этапе принятия решения. Результаты сопоставления глубин оценивались визуально и по коэффициенту корреляции Пирсона. Авторы отмечают, что подход уступает традиционным методам, поскольку не учитывает локальные растяжения и сжатия разреза, а также изменение информативности отдельных каротажных признаков вдоль глубины.

Авторами [65] был предложен новый подход, основанный на многоуровневой сети вейвлет-декомпозиции (Multilevel Wavelet Decomposition Network, mWDN), интегрированной с рекуррентной сетью GRU (Gated Recurrent Unit), дополненной DTW (рисунок 11). Многоуровневая позволяет извлекать частотную информацию из данных каротажа, обеспечивая детальное понимание сложных геологических особенностей. Рекуррентные блоки сети эффективно собирают информацию о глубинных закономерностях, обогащая контекстуальное понимание залегания пород. Алгоритм DTW здесь используется для согласования и коррекции глубины. Предлагаемая модель способна определять ключевые точки совпадения глубин среди различных каротажных кривых, создавая кривую выравнивания на основе гамма-каротажа для последующего использования в DTW. Ключевая идея этого подхода состоит в одновременном использовании как информации о динамике глубины, так и частотных признаков. Также в работе авторы для обогащения обучающей выборки представляют способ аугментации данных, включающий сжатие и растяжение. Близкий подход рассматривается в работе [66], где задача стратиграфической корреляции формулируется как поиск положений границ по каротажным данным. Для выделения локальных изменений формы сигнала применяется архитектура нейронной сети U-Squared Net (U<sup>2</sup>-Net) с механизмами пространственного и канального внимания. Хотя использование блоков внимания и повышает чувствительность модели к участкам, соответствующим геологическим границам, качество результатов в большей степени определяется точностью экспертной разметки.




Рисунок 11. Схема архитектуры mWDM [65].

Несмотря на активное развитие разнообразных архитектур нейронных сетей, для получения качественных результатов необходимо обладать большим объёмом размеченных данных, что является достаточно трудоемкой задачей. Разметка производится опытными геологами, что требует много времени и кропотливой работы. Важно отметить, что точность обучающих меток играет важную роль в качестве результатов моделей глубокого обучения.

Анализ существующих работ показывает, что наряду с бурным развитием нейросетевых подходов, алгоритм DTW остается одним из наиболее применимых для задач сопоставления последовательностей благодаря появлению новых модификаций, повышающих точность, таких как DDTW [55], FastDTW [67], shapeDTW [68], anchored DTW [69], D3TW: Discriminative Differentiable Dynamic Time Warping [70], EventDTW [71]. Наиболее перспективным выглядит применение и адаптация вышеупомянутых модификаций алгоритма DTW для задачи геологической корреляции, поскольку этот метод на протяжении многих лет хорошо зарекомендовал себя, в том числе благодаря отсутствию необходимости предварительно размечать большое количество скважин для обучения. Применение новых модификаций алгоритма потенциально позволит справиться с некоторыми ранее упомянутыми недостатками этого метода и повысить точность

геологической корреляции. Также одним из интересных направлений можно выделить развитие подхода к аугментации данных каротажа с целью увеличения объёма выборки для обучения глубоких нейронных сетей, поскольку одним из основных препятствий в применении нейросетевых решений зачастую является именно отсутствие большой качественно размеченной выборки.

Помимо выбора оптимального соответствия  $\pi$ , для прикладных задач важна локальная оценка надёжности выравнивания: каротажи могут содержать шумовые совпадения, разрывы структур и участки, где выравнивание плохо определено. В этой связи методологически оправданной является идея двухпроходной (двунаправленной) динамики. В вероятностных моделях последовательностей аналогичный принцип реализуется в forward–backward процедурах, где информация «слева» (префикс) и «справа» (суффикс) объединяется для получения локальных оценок согласованности с контекстом всей последовательности [72]. Похожая логика используется и в энергетических формулировках разметки последовательностей, например, в conditional random fields (CRF), где решение трактуется как конфигурация минимальной энергии, а локальные оценки зависят от совокупности потенциалов по всей структуре [73].

В терминах оптимизации и компьютерного зрения язык энергии широко используется для интерпретации задач поиска оптимальной конфигурации (пути, разметки, сегментации) как минимизации энергетического функционала; при этом анализ «энергетического ландшафта» позволяет выделять устойчивые области решения и диагностировать зоны, где модель поддерживается слабо [74, 75]. В задачах выравнивания временных рядов аналогичная идея естественно переносится на матрицу затрат: объединение накопленных стоимостей при прямом и обратном проходе позволяет построить карту, отражающую локальную устойчивость соответствия, и использовать её для выявления наиболее надёжного устойчивого фрагмента пути выравнивания.

### 1.3. Методы анализа азимутального плотностного каротажа

#### 1.3.1. Постановка задачи

Основная цель геонавигации в горизонтальной секции – провести скважину с наибольшим охватом целевого интервала. Для оценки положения ствола относительно кровли и подошвы пласта и своевременной коррекции траектории бурения анализируются различные геофизические данные, включая азимутальные измерения (в частности, азимутальный плотностной каротаж).

Азимутальные данные по квадрантам (имидж) представляют собой сигнал, измеренный вокруг стенки скважины, который при разворачивании цилиндрической поверхности в 2D-плоскость образует изображение. Из-за геометрии развёртки границы пластов, пересекаемые стволом, визуальнo проявляются как криволинейные структуры, часто близкие к синусоидальным паттернам (рисунок 12).




Рисунок 12. Пример данных азимутального каротажа.

При пересечении стволом скважины породы вниз по напластованию нижний сенсор (центральные секторы имиджа) отбивает пропласток первым, затем отбивают правый и левый боковые сенсоры, и последним пропласток отбивается верхним сенсором (края имиджа); таким образом формируется «грустная улыбка». При пересечении пропластка вверх по напластованию порядок отбивки сенсорами будет обратный – формируется «веселая улыбка» (рисунок 13). По длине и форме «улыбки» могут оцениваться количественные характеристики – угол падения структуры и то, откуда пришло изменение породы (кровля/подошва).




Рисунок 13. Механизм образования «веселой улыбки».

На практике выделение «улыбок» выполняется инженером вручную и требует настройки контрастности на интервале; в одной скважине число таких объектов может достигать десятков, и визуально уверенно выделяется около 70 % структур. Поэтому актуальна формализация и автоматизация интерпретации.

Практическая значимость анализа азимутальных данных при геонавигации подтверждается работой [76], где результаты структурной интерпретации имиджера плотности совместно с данными картографа границ и сейсмическими данными использовались для уточнения геологической модели и увеличения эффективной проводки горизонтальной скважины.

Несмотря на геофизическую природу исходных данных, представление азимутального каротажа в виде двумерного изображения позволяет формализовать задачу автоматической интерпретации в терминах распознавания образов и компьютерного зрения.

Пусть задано изображение азимутального плотностного каротажа, представленное в виде матрицы  $I \in \mathbb{R}^{H \times W}$ , где  $H \in \mathbb{N}$  – число отсчётов по глубине (вертикальный размер изображения),  $W \in \mathbb{N}$  – число азимутальных секторов измерения (как правило,  $W = 8$  или  $W = 16$ ),  $\mathbb{R}^{H \times W}$  – пространство вещественных матриц размера  $H \times W$ .

Обозначим через  $L = \{L_i\}$  множество границ, присутствующих на изображении в виде криволинейных структур. Задача может быть сформулирована как определение множества локализаций  $B = \{b_i\}$ , где каждый объект  $b_i$  задаёт

область изображения, содержащую структуру  $L_i$ . В простейшем случае локализация может задаваться ограничивающим прямоугольником  $b_i = (x_i, y_i, w_i, h_i)$ , где  $(x_i, y_i)$  – координаты верхнего левого угла,  $(w_i, h_i)$  – ширина и высота прямоугольника в пикселях. В задачах интерпретации азимутальных имидж-логов часто используется упрощение  $x_i \approx 0$  и  $w_i \approx W$ , поскольку граница, как правило, прослеживается по всем секторам, а основная неопределённость связана с положением по глубине  $y_i$  и вертикальным масштабом  $h_i$ .

В зависимости от выбранного метода локализация может быть представлена не только ограничивающими прямоугольниками, но и пиксельными масками или параметрическими кривыми; при этом указанные формы представления сводимы друг к другу. Таким образом, в широком смысле задача анализа азимутального каротажа может быть сведена к построению отображения

$$B = \Phi(I), \quad (1.9)$$

где  $B$  – множество локализаций геологических границ, а  $\Phi$  реализуется либо детерминированным алгоритмом обработки изображений, либо обучаемой моделью.

### 1.3.2. Типовые подзадачи компьютерного зрения в анализе имиджей

В рамках введённой постановки задача автоматического выделения «улыбок» включает несколько типовых подзадач, характерных для компьютерного зрения:

1. улучшение качества изображения (preprocessing) – подавление шума, нормализация контраста, стабилизация статистик изображения;
2. выделение контрастных переходов – построение карт градиентов и контуров, на которых проявляются резкие изменения каротажного изображения;
3. отбор криволинейных структур – поиск контуров, которые по форме могут соответствовать геологическим границам;
4. сегментация или трассировка – выделение области границы;
5. оценка геометрии – определение параметров найденной структуры (угол падения, направление).

Эти подзадачи можно рассматривать как части одной последовательности обработки изображения. Но с точки зрения применяемых для решения этих задач методов, их можно отнести к трём группам: классические алгоритмы компьютерного зрения, геометрические и частотные методы, методы машинного и глубокого обучения.

### 1.3.3. Классические алгоритмы обработки изображений

До распространения нейросетевых моделей в основном геофизические изображение обрабатывались методами фильтрации, выделения границ и анализа контуров.

#### *Подавление шума и восстановление структуры*

В работе [77] были заложены основы применения медианной фильтрации и фазовых атрибутов для выделения горизонтов в сейсмических данных. Эти методы до сих пор применимы в условиях низкого уровня шума и простых геологических структур. Для имиджей медианная фильтрация и подобные нелинейные фильтры полезны как способ подавления импульсных выбросов при сохранении контуров. Авторы статьи [78] применили методы «edge-preserving smoothing» для работы с сейсмическими данными на гексагональной сетке, эффективно подавляя шумы при сохранении резких границ. Для азимутального каротажа аналогичная идея особенно важна: грубое сглаживание может «смывать» тонкие границы и ломать форму «улыбки», поэтому предпочтительны методы, которые подавляют шум, но сохраняют контурные структуры.

С точки зрения общей постановки такие методы не решают задачу детекции напрямую, но улучшают отделимость структур  $L_i$  на изображении  $I$ , снижая число ложных кандидатов при формировании множества  $B$ .

#### *Детекторы границ*

Большая часть классических методов выделения структур строится на идее, что геологическая граница проявляется как локальный перепад сигнала. В рамках

цифровой обработки изображений это соответствует выделению границ по градиенту, лапласиану, а также комбинированным схемам с подавлением немаксимумов и пороговыми связями. Такие методы часто используются как этап формирования «кандидатных пикселей» границы, после чего выполняется геометрическая обработка (выделение линий/кривых/сегментов). Детектор границ Canny [79] остаётся классическим выбором: он сочетает сглаживание, градиентную оценку, подавление немаксимумов и пороговую связь (hysteresis), обеспечивая «тонкие» и достаточно устойчивые границы.

В терминах общей постановки детекторы границ используются для получения промежуточного представления  $E(I)$  (карты границ), по которому далее формируется набор кандидатов  $B$  (например, через связные компоненты и ограничивающие прямоугольники).

### *Морфологическая обработка и шаблонные методы*

После детекции контуров применяются морфологические операции, фильтрация связных компонент и шаблонный поиск, позволяющие «сшивать» разрывы и удалять шумовые элементы [80]. Такие методы эффективны при стабильном контрасте и относительно простой геологии, однако чувствительны к вариативности формы и условий съёмки. Для имиджей это применимо как пост-процессинг: можно «сшивать» разрывы границы, удалять мелкие шумовые компоненты, выделять протяженные кривые структуры.

Для имиджей азимутального каротажа характерны нестационарный контраст, локальные выбросы и участки с пониженным отношением сигнал/шум, из-за чего предварительная фильтрация становится ключевым этапом выделения границ. Классические методы эффективны при умеренном шуме и стабильных статистиках данных, однако в реальных данных азимутального каротажа часто наблюдаются: нестационарная яркость, смена литологии, локальные провалы сигнала, наложение нескольких структур. Поэтому одной только «классики» обычно недостаточно для устойчивой детекции всех «улыбок» без пропусков и ложных срабатываний.

### 1.3.4. Геометрические и частотные методы

Вторая группа подходов опирается на явное описание геометрической формы структур или на частотно-масштабные преобразования. В отличие от классических методов фильтрации, данные подходы используют априорные предположения о форме и непрерывности объектов и направлены не только на их обнаружение, но и на извлечение интерпретируемых геометрических параметров.

#### *Преобразование Хафа и параметрические модели*

Преобразование Хафа [81] относится к классическим методам поиска параметризованных геометрических объектов на изображении. В геофизических задачах оно может использоваться для выделения трещин, разломов и других протяжённых структур. Например, авторы статьи [82] показали возможность применения этого преобразования Хафа для автоматического выявления трещин в геофизических изображениях. Этот подход был развит в работе [83], где градиентный анализ и преобразование Хафа использовались для детекции каверн и трещин в каротажных изображениях. Для распознавания геологических границ на азимутальных имиджах такой подход применим ограниченно, поскольку требует заранее заданной формы кривой и диапазонов её параметров, а при шуме и неполных контурах приводит к росту числа ложных срабатываний.

#### *Робастная аппроксимация и RANSAC*

При работе с зашумленными данными и неполными контурами важную роль играет робастная оценка параметров. Классическим примером такого подхода является алгоритм RANSAC [84], позволяющий подбирать параметры модели по подмножествам данных и выбирать решение с максимальной поддержкой. В задачах анализа имиджей данный подход может использоваться для подгонки синусоидальных кривых или сплайнов к набору точек границы после предварительного выделения контуров.

### *Группировка криволинейных элементов и перцептивные методы*

Альтернативным направлением являются методы, ориентированные на группировку локальных элементов границы в единую криволинейную структуру. Авторами работы [85] были разработаны методы выделения криволинейных объектов на бинарных изображениях, основанные на триангуляции Делоне и принципах перцептивной группировки. Для имиджей идея «перцептивной группировки» близка к практическому смыслу: инженер визуально собирает границу из локальных фрагментов, игнорируя разрывы и шум. Алгоритмически это означает необходимость устойчиво соединять локальные сегменты границы в единую кривую, используя ограничения на гладкость, кривизну и непрерывность.

### *Активные контуры и деформируемые модели*

Ещё одним классом геометрических методов являются активные контуры и деформируемые модели. Классическая модель «snakes», предложенная в [86], основана на минимизации энергетического функционала, сочетающего притяжение к границе и регуляризацию формы контура. В задачах анализа азимутальных имиджей активные контуры позволяют «прилипнуть» к геологической границе даже при наличии разрывов и шумов, после чего геометрические параметры могут быть извлечены из полученного контура. Основные ограничения таких методов связаны с необходимостью настройки весов энергетических членов и чувствительностью к локальным минимумам, однако концептуально они заложили многие идеи регуляризации, используемые и в более современных моделях.

В рамках общей постановки активный контур можно трактовать как способ уточнения локализации объекта: начиная от грубой области-кандидата  $b_i$  (или начальной кривой), оптимизация энергетического функционала уточняет границу структуры  $L_i$  на изображении  $I$ .

### *Параметрический подбор синусоидальных границ*

Специализированным примером геометрического подхода является метод автоматического подбора синусоидальных кривых, представленный в патенте [87]. В нём используется минимизация дисперсии сигнала и анализ профиля контраста для определения параметров границы. Данный подход непосредственно отражает специфику задачи «улыбок»: форма объекта заранее ограничена параметрическим семейством, а цель интерпретации состоит не только в обнаружении границы, но и в вычислении её параметров, связанных с углом падения и положением пласта. Ограничением метода является чувствительность к отклонениям реальной структуры от идеальной синусоиды и рост сложности при расширении параметрической модели.

### *Частотные и многомасштабные методы*

Помимо явных геометрических моделей, в задачах анализа геологических изображений применяются частотные и многомасштабные подходы. Геологические границы и текстуры проявляются на разных масштабах. Многомасштабные подходы (scale-space) позволяют искать структуры устойчиво к масштабу и шуму; эта линия идей хорошо описана в фундаментальной литературе по CV [88] и в классических направлениях scale-space анализа. Для геофизических данных также широко используются преобразования в частотной области (Фурье, вейвлеты, локальные спектральные атрибуты), которые усиливают структурные элементы и подавляют шумовую составляющую. Как правило, такие методы используются в качестве вспомогательного этапа, улучшающего последующую геометрическую интерпретацию.

### *Мультимодальные и трёхмерные геометрические подходы*

Отдельное направление представляют мультимодальные и 3D-методы, в которых геометрическая интерпретация осуществляется на основе нескольких типов измерений. В работе [89] предложен подход, совмещающий оптические и радарные данные для трёхмерного восстановления изображения стенки скважины

с последующим синусоидальным приближением геологических границ. Несмотря на высокую точность, подобные методы требуют значительных вычислительных ресурсов, что ограничивает их применение в условиях реального времени.

Геометрические и частотные методы удобны, когда форма искомой границы заранее достаточно понятна. В задаче анализа имиджей это соответствует случаю, когда «улыбка» рассматривается как близкая к синусоидальной структура. Но ограничение этих методов связано с реальными данными – если в них есть шум или разрывы контуров, это нарушает предполагаемую форму границы.

### **1.3.5. Методы машинного и глубокого обучения**

По мере роста доступности вычислительных ресурсов в задачах анализа геофизических изображений стали применять обучаемые модели. В отличие от классических методов, такие методы позволяют подбирать признаки по данным, не задавая их заранее.

#### *Распознавание образов и классические ML-подходы*

В ранних ML-подходах изображения описывались градиентными, текстурными или геометрическими признаками, а после по ним уже обучался классификатор [90, 91]. Их достоинство – относительно небольшая потребность в размеченных данных, недостаток – ограниченная обобщающая способность.

Достоинство подхода – меньшая потребность в больших размеченных выборках (по сравнению с end-to-end DL). Недостаток – ограничение выразительности: признаки, придуманные человеком, часто плохо обобщаются на новые скважины/условия и требуют ручной настройки. Кроме того, «улыбки» имеют вариативность, зависящую от траектории, свойств инструмента, шумности и геологии, и «жёсткие» признаки могут терять устойчивость.

С развитием вычислительных ресурсов и доступности данных значительная часть задач интерпретации геофизических изображений стала решаться методами глубокого обучения. Ключевое отличие от классических ML-подходов – переход

от ручного проектирования признаков и правил к обучаемым моделям, которые могут автоматически извлекать информативные признаки из данных.

### *Сверточные нейронные сети (CNN)*

Ранние идеи успешного применения свёрточных сетей в распознавании изображений широко обсуждаются в обзорной работе LeCun [92]. В современном виде «взрыв» CNN-подходов в компьютерном зрении связан с успехом глубоких сетей на ImageNet [93], а развитие архитектур (например, остаточные сети ResNet) заметно улучшило обучение глубоких моделей и качество распознавания [94].

В геологическом контексте CNN стали активно использоваться для классификации по изображениям (например, литология/тип структуры). В работе [95] сверточные нейронные сети применяются для классификации литологии по данным азимутального каротажа. Полученная авторами точность показывает, что такие изображения содержат признаки, пригодные для автоматического распознавания, но качество моделей существенно зависит от объема обучающей выборки. В работе [96] используется похожая схема, но уже для выделения трещин и границ пластов на акустических и электронных каротажах (рисунок 14). Сначала авторы используют предварительную фильтрацию шума и затем выделяют структуры с помощью нейронной сети. Такая логика близка к выбранному в текущей работе подходу, где фильтрация и классификация рассматриваются как отдельные шаги обработки данных.




Рисунок 14. Пример выделения границ на изображениях бокового каротажа [96]:

(a) исходное изображение, (b) результат предварительной фильтрации, (c) выделенные нейронной сетью структуры, (d) экспертная разметка.

#### *Сегментация: FCN, U-Net, DeepLab*

Задачу выделения «улыбок» можно рассматривать и как задачу семантической сегментации, если для каждого пикселя оценивать его принадлежность к геологической границе.

Развитие сегментационных моделей связано с полносверточными нейронными сетями (FCN) [97] и архитектурами U-Net и DeepLab [98, 99]. Их преимущество состоит в том, что они совмещают локализацию объекта и контекст изображения. Для геофизических данных похожие подходы применялись, например, при выделении сейсмических горизонтов [100]. Но в случае ограниченной разметки качество таких моделей может быть недостаточно высоким и сильно зависеть от измеряющих приборов и геологии.

Близкая по постановке задача выделения протяжённых геологических объектов рассматривается в работе [101], где автоматическая корреляция отражающих горизонтов по сейсмическим данным формулируется как задача сегментации с использованием нейронных сетей.

### *Алгоритмы трассировки и «поиск пути» как альтернатива сегментации*

В работе [102] предложен метод автоматического извлечения трещин в изображениях каротажа на основе поиска оптимального пути (рисунок 15). Применяется усовершенствованный алгоритм муравьиной колонии, который позволяет эффективно отфильтровывать шум и выделять только пиксели, соответствующие трещинам. Авторы отмечают, что этот подход демонстрирует высокую точность и значительное снижение времени обработки по сравнению с традиционными методами. Для рассматриваемой задачи выделения «улыбок» данный подход может рассматриваться как промежуточный этап – вместо полной сегментации ищется наиболее вероятная траектория границы при заданных ограничениях на гладкость и непрерывность.




Рисунок 15. Сравнение результатов распознавания трещин на изображениях каротажа: исходные данные (Sample), экспертная разметка (Ground Truth), результат пороговой обработки (Maximum entropy threshold) и результат метода поиска оптимального пути (Combined optimal path search) [102].

### *Детекция объектов (object detection) и real-time-ориентированные модели*

Если «улыбку» удобно представлять как объект с ограничивающим прямоугольником или параметрами (центр/длина/амплитуда), тогда возможна

постановка как детекции объектов. В терминах постановки детекция объектов непосредственно предсказывает множество  $B = \{b_i\}$  по изображению  $I$ , что особенно удобно для real-time сценариев геонавигации.

В работе [103] показано применение модели детекции для поиска трещин на каротажных изображениях в режиме, близком к реальному времени (рисунок 16). Для задач геонавигации это направление схоже, потому что требует высокой скорости обработки.




Рисунок 16. Детекция трещин на изображениях бокового каротажа [103].

### *Трансформеры и глубокие архитектуры нового поколения*

Трансформенные архитектуры применяются в компьютерном зрении для учёта связей между отдалёнными участками изображения. После появления базовой архитектуры Transformer [104] также были разработаны модели для анализа изображений, в том числе Vision Transformer [105]. Для геофизических изображений этот подход можно применить, потому что протяжённые границы могут быть описаны не только локальными признаками. Примером применения таких моделей является GeoBFDТ [106] для выделения трещин с использованием мультимодальных признаков (рисунок 17). Несмотря на потенциально высокое

качество, обучение таких моделей требует значительных вычислительных ресурсов и большой обучающей выборки.




Рисунок 17. Схема архитектуры GeoBFDNet [106].

Использование трансформеров и attention-механизмов соответствует современному тренду в компьютерном зрении: модели стремятся учитывать дальние зависимости и глобальный контекст изображения. Для азимутальных имиджей это потенциально важно, поскольку «улыбка» может быть протяжённой и частично скрытой шумом, но практическая эффективность таких моделей сильно зависит от объёма обучающих данных.

Полезно упомянуть несколько обзорных работ, которые фиксируют общую картину применения DL в геонауках и сейсмике. Так, обзор [107] рассматривает состояние и перспективы Deep Learning в геофизике, обсуждая типовые проблемы (дефицит данных, переносимость между месторождениями, неопределённость, интерпретируемость) и направления развития. Для задач сейсмической сегментации полезны систематические обзоры по DL-сегментации в сейсмике, где сравниваются архитектуры, функции потерь, публичные датасеты и метрики [108]. Также встречаются обзоры по DL-интерпретации разломов и структур на сейсмических данных [109], что методологически близко к выделению криволинейных структур на имидж-логах.

### *Автоэнкодеры и подавление шума*

Одним из способов восстановления «полезной структуры» является использование автоэнкодеров и их модификаций. Автоэнкодер обучается восстанавливать входное изображение из сжатого латентного представления, что

приводит к формированию компактных признаков, устойчивых к шуму и локальным искажениям. Особый класс – денойзинг-автоэнкодеры, в которых сеть обучается восстанавливать исходные данные из зашумленного варианта; такой принцип позволяет явно моделировать подавление шумовой компоненты и сохранять структурные элементы изображения. Базовые принципы денойзинг-автоэнкодеров и их способность обучать робастные представления описаны в классической работе [110].

Для задач геофизики и обработки сейсмики также показывается эффективность автоэнкодеров именно как инструментов подавления случайного шума при сохранении геологически значимых структур; например, в работе [111] предложено подавление случайного шума на основе deep denoising autoencoder в задаче сейсмической обработки (рисунок 18). Для подавления шума на изображениях также применяются денойзинговые сверточные сети, например, DnCNN [112], где модель обучается выделять шумовую составляющую и восстанавливать очищенное от шума изображение.




Рисунок 18. Архитектура глубокого денойзингового автоэнкодера (DDAE) [111].

В задаче анализа азимутального каротажа автоэнкодер используется как обучаемый этап предобработки изображения. Его задача состоит в том, чтобы получить реконструированное изображение  $\hat{I}$ , в котором часть шума подавляется и при этом сохраняются контрастные границы. Это упрощает последующее построение множества кандидатов В.

Таким образом, анализ азимутального плотностного каротажа в виде развернутого имиджа может рассматриваться как частный случай задач компьютерного зрения, включающий детекцию криволинейных структур,

сегментацию границ и последующую параметрическую аппроксимацию. Историческая эволюция подходов в данной области соответствует общему развитию методов обработки изображений и распознавания образов: от фильтрации и градиентных детекторов, через геометрические и частотные методы, к статистическому распознаванию и далее к глубоким нейросетевым архитектурам.

Рассмотренные публикации показывают, что современные решения для автоматической интерпретации азимутальных каротажных изображений и сейсмических данных развиваются по трём направлениям:

- (1) классические интерпретируемые фильтры и детекторы,
- (2) геометрические/частотные методы с явной параметризацией структур,
- (3) глубокие нейросетевые модели (CNN/segmentation/detection/transformers).

Анализ литературы показывает, что на практике наилучшие результаты достигаются при гибридном подходе, сочетающем предварительную фильтрацию, обучаемые модели для выделения кандидатов и геометрическую аппроксимацию для извлечения интерпретируемых параметров. Такая стратегия хорошо согласуется с общей постановкой задачи и требованиями геонавигации в реальном времени.

### **1.3.6. Подходы к оценке качества и обучению моделей в задачах анализа геофизических изображений**

В дополнение к разнообразию алгоритмических подходов, в литературе по автоматической интерпретации геофизических изображений сформировался набор типовых практик оценки качества решений и обучения моделей, во многом заимствованный из компьютерного зрения и задач распознавания образов. С точки зрения общей постановки задачи автоматического анализа азимутальных имиджей данные практики определяют, каким образом оценивается качество построения локализаций геологических границ  $B$  по изображению  $I$ , а также устойчивость и интерпретируемость полученных решений. Выбор метрик качества, функций потерь и алгоритмов оптимизации, как правило, определяется формулировкой задачи (детекция, сегментация, восстановление структуры или параметрическая

аппроксимация), а также особенностями геологических данных, такими как высокая шумность, выраженный дисбаланс классов и неполнота или разрывность интерпретируемых структур.

### *Метрики оценки качества*

Для задач детекции геологических объектов (границ пластов, трещин, разломов) в компьютерном зрении и смежных прикладных областях наиболее распространёнными являются метрики точности и полноты (precision, recall), а также их гармоническое среднее – F1-score [113]. Эти метрики позволяют отдельно учитывать полноту обнаружения и долю ошибочных срабатываний, что особенно важно в анализе геофизических изображений.

Если алгоритм, реализующий модель, возвращает помимо факта наличия объекта конкретную область, дополнительно можно оценить качество локализации. Для этого используется IoU – отношение площади пересечения предсказанной и размеченной областей к площади их объединения. В задачах детекции IoU обычно задает правило, по которому предсказанием считается совпавшим, а на его основе затем рассчитываются метрики AP и mAP [114]. В данной работе этот критерий нужен, чтобы оценить, насколько точно область найденной «улыбки» соответствует выделенным «улыбкам» из экспертной разметки.

Для моделей сегментации качество обычно считают по совпадению предсказанной и эталонной масок. Чаще всего для этого используют коэффициент IoU и Dice [115]. Но для тонких протяжённых структур, таких как «улыбка» на имидже, эти метрики могут не всегда отражать качество, поскольку разрывы линии могут ухудшить пиксельную оценку. Поэтому в задаче анализа границ важно учитывать не только площадь совпадения масок, но и сохранение формы и связности.

### *Функции потерь и критерии обучения*

При обучении моделей восстановления изображений, в том числе автоэнкодеров, часто используют квадратичную функцию потерь MSE. Но такой критерий ориентирован на покомпонентное совпадение значений и не всегда адекватно отражает качество восстановления структурных элементов изображения. В качестве альтернативы существуют структурные меры сходства, наиболее известной из которых является Structural Similarity Index Measure (SSIM), учитывающая локальные статистики яркости, контраста и структуры изображения [116]. Использование SSIM и аналогичных критериев позволяет направить обучение модели на сохранение геометрии и контрастных переходов, что критично для последующей интерпретации границ пластов. С точки зрения общей постановки такие функции потерь позволяют обучать отображение  $I \mapsto \hat{I}$ , сохраняющее структурные элементы, которые далее используются для построения локализаций геологических границ.

В задачах сегментации и детекции широко применяются функции потерь на основе кросс-энтропии, а также их модификации и комбинации с региональными метриками (Dice loss, IoU-based loss). Такие подходы подробно описаны в работах, посвящённых fully convolutional networks и архитектурам семейства U-Net и DeepLab [97, 98, 99]. Для структурных задач нередко используются комбинированные функции потерь, включающие несколько слагаемых (например, бинарную кросс-энтропию и Dice-loss), что позволяет одновременно учитывать точность классификации и геометрию выделяемых объектов [117]. В задачах детекции и сегментации данные критерии обучения непосредственно направлены на оптимизацию качества восстановления множества  $B$  или его пиксельного представления.

### *Алгоритмы оптимизации*

Что касается алгоритмов оптимизации, в современных нейросетевых моделях для анализа геофизических изображений наибольшее распространение получили адаптивные методы стохастической оптимизации. Одним из наиболее

широко используемых алгоритмов является Adam, который сочетает идеи адаптивного выбора шага обучения и экспоненциального сглаживания моментов градиента [118]. Практика применения Adam и его модификаций показала их устойчивость при обучении глубоких моделей на шумных и неоднородных данных, характерных для задач интерпретации каротажных и сейсмических изображений [119]. Выбор подобных оптимизаторов обусловлен необходимостью устойчивого обучения отображений, используемых для восстановления структур и локализаций в условиях высокой шумности и неоднородности входных изображений *I*.

Более общий обзор методов оптимизации, включая стохастический градиентный спуск, методы с моментумом и адаптивные алгоритмы, приведён в фундаментальных работах по оптимизации и машинному обучению [120, 121]. В большинстве прикладных исследований выбор конкретного оптимизатора обусловлен не столько теоретическими соображениями, сколько требованиями к устойчивости сходимости и скорости обучения модели.

Таким образом, практики оценки качества и обучения моделей в задачах автоматической интерпретации геофизических изображений в значительной степени опираются на общие принципы компьютерного зрения и машинного обучения. При этом используемые метрики, функции потерь и алгоритмы оптимизации адаптируются с учётом специфики геологических данных и целевых инженерных показателей, что позволяет корректно сопоставлять различные методы и обосновывать выбор конкретных решений в прикладных задачах. В рамках введённой ранее постановки задачи эти практики определяют способы количественной оценки качества построения локализаций геологических границ и устойчивости извлечения их геометрических характеристик.

В настоящей работе формализуется и развивается подход к распознаванию паттернов «улыбок» и извлечению их количественных характеристик с использованием методов цифровой обработки изображений и глубокого обучения, при этом учитываются практические ограничения геонавигации: шумность, неоднородность данных, неполнота структур и требования к устойчивости и скорости вычислений.

## Основные выводы к главе 1

Проведённый в главе анализ современных методов и подходов к автоматизации геонавигации и интерпретации геофизических данных позволяет сделать следующие выводы:

1. Для задач геологической корреляции в транспортной секции скважины в литературе предложен широкий спектр методов, включая классические корреляционные алгоритмы, методы динамического программирования (DTW и его модификации), геометрические и оптимизационные подходы, а также модели машинного и глубокого обучения. Наиболее устойчивыми и широко применяемыми на практике остаются методы, основанные на динамическом программировании, благодаря их способности учитывать нелинейные искажения по глубине, работать с неполными и зашумлёнными данными и не требовать больших объёмов размеченной информации. Вместе с тем существующие реализации часто ограничиваются поиском единственного оптимального соответствия и не обеспечивают локальной оценки надёжности корреляции, что снижает устойчивость решений в условиях сложной геологии.
2. Задачу интерпретации азимутального плотностного каротажа в горизонтальной секции удобно рассматривать как задачу компьютерного зрения. Геологические границы на таких данных проявляются как протяжённые криволинейные структуры, поэтому для их поиска применимы различные методы детекции и сегментации. Классические и геометрические методы дают интерпретируемый результат, но чувствительны к шуму и качеству изображений. В отличие от классических алгоритмов, нейросетевые модели формируют признаки автоматически на основе обучающей выборки и не требуют явного задания характеристик искомых объектов. Но при смене литологии месторождения или замены приборов модель может требовать дополнительной проверки.

3. Анализ работ по автоматизации геонавигации показывает, что модульные решения являются более удобными для производственных задач. Они не заменяют весь процесс геонавигации, а автоматизируют отдельные операции. Такие подходы позволяют снизить нагрузку на инженера-геонавигатора, повысить воспроизводимость интерпретаций и сохранить совместимость с существующими производственными рабочими процессами.
4. Исходя из проведённого анализа существующих методов и программных решений, а также с учётом выявленных ограничений – чувствительности к шуму и геологической неоднородности, недостаточной локальной оценки надёжности решений, высокой зависимости от качества разметки и ограниченного числа реализованных промышленных программных продуктов – остаётся актуальной задача разработки моделей и методик для корреляции разрезов скважин и интерпретации азимутальных каротажных данных. Особый интерес представляет создание воспроизводимых, устойчивых к неопределённостям и вычислительно эффективных алгоритмов, ориентированных на практическое применение и интеграцию в единое программное обеспечение поддержки геонавигационных решений.

## ГЛАВА 2. МЕТОДИКА УТОЧНЕНИЯ ПОЛОЖЕНИЯ КРОВЛИ ЦЕЛЕВОГО ПЛАСТА ПРИ БУРЕНИИ ТРАНСПОРТНОЙ СЕКЦИИ СКВАЖИНЫ

### 2.1. Постановка задачи

Пусть вдоль ствола каждой скважины задана упорядоченная последовательность значений глубины  $z = (z_1, z_2, \dots, z_N)$ , соответствующих точкам регистрации каротажных измерений. В дальнейшем под глубиной  $z$  будем понимать приведённую абсолютную глубину, отсчитанную от уровня моря (TVDSS).

Обозначим через  $W = \{w_1, w_2, \dots, w_K\}$  множество пробуренных опорных скважин, а через  $w_H$  – разбуриваемую скважину. Пусть  $M = \{m_1, m_2, \dots, m_L\}$  – множество геологических маркеров пластопересечений, упорядоченных по глубине, где маркер  $m_L$  соответствует кровле целевого интервала (ЦИ). Для каждой опорной скважины  $w_k \in W$  положения маркеров считаются известными и задаются значениями глубины  $z(w_k, m_1) > z(w_k, m_2) > \dots > z(w_k, m_L)$ , что отражает их упорядоченность вдоль ствола скважины.

Задача геологической корреляции для пары скважин заключается в нахождении соответствия между элементами каротажных кривых, зарегистрированными вдоль глубины, при сохранении порядка следования измерений.

Пусть известны каротажные данные, полученные в двух скважинах  $y^{(1)} = (y_1^{(1)}, \dots, y_n^{(1)})$ ,  $y^{(2)} = (y_1^{(2)}, \dots, y_m^{(2)})$ , где  $y_i^{(1)} = y^{(1)}(z_i)$  – значение каротажа в скважине 1, полученное на глубине  $z_i$ ,  $n, m \in \mathbb{N}$  – длины первой и второй каротажных последовательностей соответственно. Корреляция формулируется как задача поиска такого соответствия между элементами этих последовательностей, при котором суммарное различие между сопоставленными значениями минимально согласно выбранной мере несходства  $f(\cdot, \cdot)$ . Под соответствием здесь понимается не взаимно однозначное отображение, а упорядоченное сопоставление элементов с сохранением порядка их глубины.

В зависимости от выбранных ограничений на допустимые соответствия и формы функции  $f$ , данная постановка допускает различные методы решения. В настоящей работе для нахождения соответствия между интервалами каротажей используется методика, основанная на алгоритмах динамического программирования, в частности на модификациях алгоритма динамической трансформации временной шкалы.

При выборе метода решения задачи корреляции в транспортной секции необходимо учитывать ряд практических ограничений, характерных для геонавигации в реальном времени. Во-первых, данные каротажа в разбуриваемой скважине поступают последовательно и часто содержат шум и локальные искажения, обусловленные условиями бурения и свойствами бурового раствора. Во-вторых, интервалы каротажей в опорных и разбуриваемой скважинах, как правило, имеют различную длину и не совпадают по абсолютным глубинам вследствие вариативности мощностей пластов и неопределённости структуры.

Классические корреляционные методы, основанные на линейном сдвиге или глобальной оптимизации коэффициента корреляции, не позволяют корректно учитывать локальные сжатия и растяжения по глубине. Методы машинного обучения и глубокие нейронные сети требуют значительных объёмов размеченных данных и обладают ограниченной интерпретируемостью, что затрудняет их применение в условиях промышленной геонавигации.

В этой связи алгоритмы динамического программирования, в частности динамической трансформации временной шкалы, представляют собой компромиссное решение, сочетающее устойчивость к нелинейным искажениям, отсутствие необходимости в предварительном обучении и возможность явной интерпретации полученного соответствия между элементами каротажных кривых.

В настоящей работе каротажные кривые рассматриваются как упорядоченные последовательности значений, индексированных глубиной. Несмотря на то, что алгоритм динамической трансформации временной шкалы изначально разработан для анализа временных рядов, его математическая постановка не зависит от физической природы параметра упорядочивания. В

рамках рассматриваемой задачи глубина играет роль монотонно возрастающей параметрической переменной, аналогичной времени, что позволяет корректно применять методы выравнивания последовательностей.

## 2.2. Алгоритм динамической трансформации временной шкалы (DTW)

Алгоритм динамической трансформации временной шкалы (DTW), кратко рассмотренный в Главе 1, используется в настоящей работе в качестве базового метода сопоставления каротажных кривых. Ниже приведена его формализация, необходимая для последующего введения модификаций.

Пусть даны две каротажные кривые различной длины  $y^{(1)} = (y_1^{(1)}, \dots, y_n^{(1)})$ ,  $y^{(2)} = (y_1^{(2)}, \dots, y_m^{(2)})$ .

На первом этапе алгоритма строится локальная матрица затрат

$$d_{ij} = f(y_i^{(1)}, y_j^{(2)}), \quad i = 1 \dots n, j = 1 \dots m, \quad (2.1)$$

где  $f(\cdot, \cdot)$  – мера несходства (например, Евклидово расстояние).

На втором этапе строится глобальная матрица накопленных стоимостей  $C$ :

$$C_{ij} = d_{ij} + \min(C_{i-1,j}, C_{i-1,j-1}, C_{i,j-1}), \quad i = 2 \dots n, j = 2 \dots m, \quad (2.2)$$

с начальными условиями  $C_{11} = d_{11}$ ,  $C_{i1} = d_{i1} + C_{i-1,1}$ ,  $C_{1j} = d_{1j} + C_{1,j-1}$ .

Путь выравнивания (трансформации)  $\pi$  определяется как последовательность смежных элементов матрицы  $C$ :

$$\pi = \{(i_k, j_k)\}_{k=1}^K, \quad \max(m, n) \leq K \leq m + n,$$

где  $k$  – номер шага вдоль пути выравнивания,  $i_k$  и  $j_k$  – индексы соответствующих элементов в последовательностях  $y^{(1)}$  и  $y^{(2)}$ ,  $K$  – длина пути.

Оптимальный путь выравнивания минимизирует DTW-расстояние между последовательностями:

$$DTW(y^{(1)}, y^{(2)}) = \min_{\pi \in \Pi} \frac{1}{K} \sum_{k=1}^K d(y_{i_k}^{(1)}, y_{j_k}^{(2)}), \quad (2.3)$$

где  $\Pi$  – множество допустимых путей, определяемое условиями монотонности и связности.

Алгоритм динамической трансформации временной шкалы может быть модифицирован и применен для задачи геологической корреляции, поскольку каротажные кривые в соседних скважинах различаются наличием сжатия и растяжения вследствие разницы мощностей пластов.

### **2.3. Модификации классического подхода для решаемой задачи**

Несмотря на широкое применение алгоритма DTW для сопоставления временных рядов и сигналов, его классическая формулировка не учитывает ряд специфических особенностей задачи геологической корреляции в транспортной секции скважины. В частности, стандартный DTW предполагает, что начало и конец анализируемых последовательностей соответствуют одним и тем же геологическим событиям, что в реальных условиях геонавигации, как правило, не выполняется.

Кроме того, классический критерий оптимальности ориентирован на минимизацию суммарного расстояния по всему интервалу и возвращает оптимальное соответствие без оценки его локальной устойчивости. В условиях зашумлённых данных и возможных локальных деформаций это может приводить к формально оптимальным, но геологически некорректным решениям.

В настоящей работе предлагается ряд модификаций алгоритма DTW, направленных на адаптацию метода к условиям геонавигации и повышение устойчивости получаемых решений.

#### *1. Предобработка данных*

В условиях реальных каротажных данных измерения содержат высокочастотные флуктуации, обусловленные как инструментальными шумами, так и дискретизацией сигнала. Наличие таких колебаний может приводить к формированию локальных ложных минимумов в матрице стоимостей и, как следствие, к некорректному выравниванию. В связи с этим перед построением матрицы локальных стоимостей выполняется предварительная обработка каротажных кривых. Для подавления высокочастотного шума используется сглаживание сигналов с помощью фильтра Гаусса

$$\tilde{y} = G_{\sigma} * y \quad (2.4)$$

где  $G_{\sigma}$  – гауссово ядро

$$G_{\sigma}(t) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{t^2}{2\sigma^2}\right), \quad (2.5)$$

а  $*$  обозначает операцию свёртки. Параметр  $\sigma$  определяет степень сглаживания и выбирается исходя из характерного масштаба изменчивости каротажного сигнала. Сглаживание применяется к дискретной последовательности значений каротажной кривой. Использование гауссова фильтра позволяет подавить случайные шумовые колебания при сохранении основных геологических особенностей сигнала, в частности границ пластов и характерных изменений формы кривой. В отличие от альтернативных методов сглаживания, таких как фильтр Савицкого–Голея, использование гауссова фильтра не приводит к появлению искусственных осцилляций сигнала, что является важным для корректной работы алгоритма динамического выравнивания.

## 2. Модификация локальной меры несходства

В классической формулировке алгоритма DTW локальная матрица затрат (1.11) определяется как функция расстояния между значениями сигналов в точках, например, в виде абсолютной или квадратичной разности. Такое определение учитывает только различие амплитуд сигналов и не учитывает их локальную структуру, что может приводить к некорректным сопоставлениям в условиях шума, различий в масштабе и наличии плавных трендов.

В настоящей работе предлагается модификация локальной меры несходства, основанная на использовании локально центрированных значений и оценки локального наклона сигнала. Для каждой точки каротажной кривой вычисляется локальное среднее в окне радиуса  $h$ :

$$\mu(i) = \frac{1}{|H_i|} \sum_{p \in H_i} \tilde{y}_p, H_i = \{p: \max(1, i - h) \leq p \leq \min(N, i + h)\}. \quad (2.6)$$

На основе локального среднего вводятся центрированные значения:

$$\tilde{y}_i^{(c)} = \tilde{y}_i - \mu(i). \quad (2.7)$$

Дополнительно вычисляется оценка локального наклона сигнала:

$$g(i) = \frac{\tilde{y}_{r_i} - \tilde{y}_{l_i}}{r_i - l_i}, l_i = \max(1, i - k), r_i = \min(N, i + k), \quad (2.8)$$

где параметр  $k$  задаёт масштаб оценки наклона.

С учётом введённых преобразований локальная мера несходства определяется как:

$$d_{ij} = \alpha \left( \tilde{y}_i^{(1)} - \tilde{y}_j^{(2)} \right)^2 + \beta \left( g_i^{(1)} - g_j^{(2)} \right)^2, \quad (2.9)$$

где  $\alpha$  и  $\beta$  – весовые коэффициенты.

Предложенная метрика позволяет учитывать не только различие амплитуд сигналов, но и их локальную форму, что повышает устойчивость сопоставления в условиях шумовых искажений и различий в масштабах каротажных данных.

### 3. *Subsequence-DTW*

Классический DTW «сшивает» начальные и конечные точки рядов, тогда как в рассматриваемой задаче требуется поиск подпоследовательности (интервала между маркерами в опорной скважине) внутри длинного каротажного интервала (в определённом диапазоне глубин транспортной секции). Для этого допускается свободный старт:  $C_{1j} = d_{1j}$ ,  $j = 1 \dots m$  и свободный финиш:  $j^* = \underset{j}{\operatorname{argmin}} C_{nj}$ , в отличие от классического DTW, где фиксируется начальная точка выравнивания. При этом глобальная матрица затрат строится с помощью рекуррентного соотношения:

$$C_{ij} = d_{ij} + \min(C_{i-1j}, C_{i-1j-1}, C_{ij-1}), i = 2 \dots n, j = 1 \dots m \quad (2.10)$$

На рисунке 19 приведена иллюстрация работы алгоритма Subsequence-DTW при поиске оптимального выравнивания короткой последовательности внутри более длинного интервала. Цветные линии соответствуют пути выравнивания, определяющему оптимальное соответствие элементов подпоследовательностей.




Рисунок 19. Иллюстрация работы Subsequence-DTW: поиск оптимального выравнивания короткой последовательности внутри протяжённого каротажного интервала.

#### 4. Выбор нескольких кандидатов на финиш

Классический DTW не предусматривает поиск по нескольким гипотезам, однако рассматриваемая задача требует использования нескольких стартовых гипотез / коридоров поиска с выбором лучшего кандидата, чтобы не зависеть от неудачного старта. В качестве кандидатов на финиш выбираются  $K$  минимальных значений  $C_{nj}$  по  $j$ . Сравнение кандидатов производится по нормированной стоимости  $C_{nj^*}/K$ .

#### 5. Матрица энергии

Классический DTW не позволяет локально оценивать соответствия точек каротажей и не имеет механизма обнаружения явно неверно сопоставленных участков вследствие шума или локальных деформаций, а также инструмента, уменьшающего зависимость результата от случайного выбора начала или конца подпоследовательности. Карта «энергии» позволяет выделять устойчивый фрагмент пути выравнивания там, где соответствие поддержано обоими направлениями динамики, объективно сравнивать кандидатов финиша не только по общей стоимости, но и по локальной устойчивости.

Карта «энергии» строится следующим образом

$$E_{ij} = C_{ij}^f + C_{ij}^b - C_{nj^*}^f, \quad (2.11)$$

где  $C_{ij}^f$  – глобальная матрица затрат «вперёд» (2.2),  $C_{nj}^f$  соответствует стоимости оптимального пути и используется для нормировки значений энергии, а  $C_{ij}^b$  – глобальная матрица затрат «назад»:

$$C_{ij}^b = d_{ij} + \min(C_{i+1j}, C_{i+1j+1}, C_{ij+1}). \quad (2.12)$$

Введение карты «энергии» позволяет перейти от глобального критерия качества выравнивания к локальной оценке надёжности соответствия. В отличие от классического DTW, где результатом является единственный путь и одно агрегированное значение расстояния, энергетическая карта отражает структуру оптимального решения в окрестности каждого элемента пути.

Использование прямого и обратного проходов динамического программирования концептуально близко к двунаправленным процедурам, применяемым в вероятностных моделях последовательностей и энергетических формулировках оптимизации. В рассматриваемой задаче это позволяет выявлять участки, где соответствие поддерживается глобальной структурой данных, а не является следствием локального шумового совпадения.

Ключевой особенностью предлагаемого подхода является отказ от интерпретации всего пути трансформации как равнозначного. Вместо этого выделяется участок пути, обладающий минимальной средней энергией и высокой локальной контрастностью сигнала, что соответствует геологически устойчивому интервалу, который может быть использован для последующего прогнозирования положения кровли целевого пласта.

Таким образом, предлагаемый подход позволяет не только находить соответствие между каротажными данными, но и количественно оценивать его надёжность, что принципиально важно для задач геонавигации в условиях неопределённости. Если в начале произошёл промах, «гребень» высокой энергии сразу проявляется вокруг неверно сопоставленного участка, в таком случае можно переинициализировать или заменить кандидата. Шумовые совпадения обычно дают области высокой  $E$ , при этом реальная структура поддерживается длинным участком низкой  $E$ . Таким образом, надёжное соответствие определяется на

отрезке с минимальной средней  $E$ , который можно выделить по скользящему окну на пути.

#### 6. Геологические ограничения области поиска

Отсутствие геологически информированных ограничений области поиска компенсируется заданием коридора (окна Сакоэ–Чиба), подавляющего недопустимые деформации:

$$M = \{(i, j): |j - c(i)| \leq \omega(i)\}, \quad C_{ij} = \infty \text{ вне } M, \quad (2.13)$$

где центр  $c(i)$  определяется  $j^*$ , а  $\omega(i)$  – полуширина окна.

Также в DTW допускаются шаги  $(1,0)$  и  $(0,1)$ , которые могут приводить к вырождениям «много-к-одному», что для геонавигации нефизично и искажает привязку интервалов. Отсутствие ограничения локального наклона пути требует введения контроля растяжения, например, допустимы только шаги  $(1,1)$ ,  $(1,2)$ ,  $(2,1)$   $\Rightarrow$  локальный наклон пути ограничен:  $\frac{\Delta j}{\Delta i} \in \{1, 2, \frac{1}{2}\}$ .

#### 7. Выделение устойчивого фрагмента пути выравнивания

Классический критерий DTW минимизирует среднюю несхожесть по всему интервалу и возвращает одно оптимальное соответствие  $\pi^*$  и одно агрегированное значение расстояния. Целью анализа является не получение соответствия по всей длине интервала, а поиск локального участка выравнивания, сохраняющего устойчивость при сопоставлении сигналов. Глубины этого участка далее используются для уточнения положения кровли целевого интервала.

Путь выравнивания  $\pi^*$  определяется обратным проходом по матрице накопленных стоимостей  $C^f$ , при этом на каждом шаге выбирается допустимая предшествующая ячейка с минимальным значением, начиная из ячейки  $(n, j^*)$  до ячейки  $(1, j_1)$ :

$$\pi^* = \{(i_k, j_k)\}_{k=1}^K \quad (2.14)$$

Найденный путь  $\pi^*$  анализируется не целиком, а по последовательным фрагментам длины  $L$ . Начало фрагмента задается индексом  $u = 1, \dots, K - L + 1$ .

Для каждого фрагмента пути рассчитывается среднее значение энергии:

$$\hat{E}(u) = \frac{1}{L} \sum_{k=u}^{u+L-1} E(i_k, j_k), \quad (2.15)$$

где  $E(i_k, j_k)$  – значение карты энергии в  $k$ -й точке пути.

Помимо энергии для того же фрагмента вычисляется локальный перепад значений сигнала:

$$\Delta(u) = \text{quantile}_{0,95}(\{y_p\}_{p=u}^{u+L-1}) - \text{quantile}_{0,05}(\{y_p\}_{p=u}^{u+L-1}), \quad (2.16)$$

где  $\{y_p\}_{p=u}^{u+L-1}$  – значения каротажного сигнала в текущем фрагменте. Значение  $\Delta(u)$  используется как простой признак информативности. Если перепад мал, участок близок к однородному и плохо подходит для уточнения положения кровли. Если перепад достаточно выражен, в фрагменте есть контрастные изменения сигнала, по которым легче проверить качество сопоставления. Разность 95-го и 5-го процентилей выбрана вместо размаха, чтобы отдельные выбросы меньше влияли на оценку.

Индекс фрагмента  $u^*$  с минимальной средней энергией выбирается как

$$u^* = \underset{u}{\operatorname{argmin}} \hat{E}(u) \text{ при } \Delta(u) \geq \Delta_{\min}, \quad (2.17)$$

где  $\Delta_{\min}$  – заданный порог минимальной информативности сигнала.

После выбора  $u^*$  нужный фрагмент пути задаётся точками с индексами от  $u^*$  до  $u^* + L - 1$ :

$$P = \{(i_k, j_k) : u^* \leq k \leq u^* + L - 1\}. \quad (2.18)$$

Данный интервал соответствует наиболее устойчивому участку выравнивания, в котором соответствие между элементами каротажных кривых поддерживается как глобальной структурой сигнала, так и локальной согласованностью. Глубины точек, входящих в  $P$ , используются для дальнейшего вычисления относительного положения кровли целевого пласта.

На рисунке 20 представлена матрица энергии  $E$ , формируемая при вычислении DTW-выравнивания. Цветовая шкала отражает накопленную стоимость сопоставления элементов рядов. Для ограничения допустимой области поиска оптимального пути используется окно Сакоэ–Чиба, задающее допустимое

отклонение от диагонали и тем самым уменьшающее вычислительную сложность и вероятность некорректных сопоставлений удалённых участков. Белой линией показан найденный оптимальный путь. В центральной части матрицы (пунктирная рамка) наблюдается область устойчивого минимума, соответствующая наиболее стабильному и информативному фрагменту выравнивания. Наличие протяжённой зоны пониженной энергии свидетельствует о согласованности сигналов в данном интервале и повышает надёжность оценки сдвига.




Рисунок 20. Матрица энергии  $E$  при вычислении DTW-выравнивания.

Для наглядной интерпретации найденного пути трансформации и выделенной области устойчивого сопоставления на рисунке 21 представлено отображение выравнивания в пространстве исходных сигналов. Выделенный зеленым фрагмент оптимального пути отражает интервалы, в пределах которых наблюдаются устойчивые соответствия сигналов. Данный интервал соответствует области пониженной энергии на матрице затрат (рисунок 20).




Рисунок 21. Выделение устойчивого фрагмента пути выравнивания.

## 2.4. Итеративный прогноз кровли целевого пласта

В предлагаемой методике используется итеративный подход, основанный на агрегировании информации от нескольких опорных скважин с применением устойчивых статистических оценок. Использование медианы вместо среднего значения позволяет снизить влияние выбросов и повысить устойчивость прогноза при ограниченном числе опорных скважин.

Последовательное уточнение положения кровли по мере прохождения маркеров обеспечивает адаптацию прогноза к поступающим данным и соответствует практическому сценарию геонавигации в реальном времени.

Пусть для каждой опорной скважины  $w_k \in W$  известно положение кровли целевого интервала  $z(w_k, m_L)$ . Рассмотрим пару соседних маркеров  $m_l, m_{l+1}$ , ограничивающих пласт  $F_{l,l+1}$ .

### *Шаг 1. Определение соответствующего интервала*

Для каждой опорной скважины  $w_k$  с использованием предложенного подхода определяется интервал в разбуриваемой скважине  $w_H$ , наибольшим образом схожий с интервалом между маркерами  $m_l$  и  $m_{l+1}$  в опорной скважине.

В результате формируется устойчивый фрагмент пути выравнивания  $P_{k,l} \subset w_H$ , соответствующий интервалу в опорной скважине. Обозначим через  $z(w_H, P_{k,l})$  глубину центра этого фрагмента в разбуриваемой скважине, а через  $z(w_k, P_{k,l})$  – соответствующую глубину в опорной скважине.

### *Шаг 2. Вычисление относительного смещения до кровли*

Для каждой опорной скважины вычисляется расстояние от положения устойчивого фрагмента пути выравнивания до кровли целевого интервала:

$$\Delta z_k^{(l)} = z(w_k, P_{k,l}) - z(w_k, m_L). \quad (2.19)$$

Величина  $\Delta z_k^{(l)}$  характеризует относительное положение кровли целевого пласта относительно интервала  $F_{l,l+1}$  в опорной скважине.

### Шаг 3. Прогноз положения кровли в разбуриваемой скважине

Оценка положения кровли целевого интервала в разбуриваемой скважине, полученная по  $k$ -й опорной скважине, определяется как

$$\hat{z}_k^{(l)}(w_H, m_L) = z(w_H, P_{k,l}) - \Delta z_k^{(l)}. \quad (2.20)$$

Итоговая оценка положения кровли после прохождения маркера  $m_l$  вычисляется как медиана по всем опорным скважинам:

$$\hat{z}^{(l)}(w_H, m_L) = \text{median} \left[ \hat{z}_k^{(l)}(w_H, m_L) \right]_{w_k \in W}. \quad (2.21)$$

Таким образом, по мере последовательного прохождения маркеров формируется последовательность уточняющихся оценок  $\hat{z}^{(1)}(w_H, m_L), \hat{z}^{(2)}(w_H, m_L), \dots, \hat{z}^{(L-1)}(w_H, m_L)$ , где  $L - 1$  – число интервалов между маркерами, используемых для последовательного уточнения прогноза.

## Основные выводы к главе 2

В результате проведённого исследования и разработки методики уточнения положения кровли целевого пласта при бурении транспортной секции скважины получены следующие основные выводы:

1. Задача уточнения положения кровли целевого пласта в транспортной секции формализована как задача геологической корреляции каротажных данных, учитывающая нелинейные деформации по глубине, различие мощностей пластов и неопределённость геологического строения. Показано, что алгоритмы динамического программирования, в частности динамическая трансформация временной шкалы, являются адекватной основой для решения данной задачи в условиях ограниченного объёма данных и требований реального времени.
2. Разработан модифицированный алгоритм DTW, адаптированный к условиям геонавигации, включающий поиск подпоследовательностей, выбор нескольких кандидатов соответствия, введение геологически информированных ограничений области поиска и контроль локальных деформаций пути выравнивания. За счёт этих изменений сопоставление

меньше зависит от отдельных шумовых участков, локальных искажений кривых и различий в строении сопоставляемых разрезов.

3. Для оценки надёжности сопоставления используется карта «энергии», построенная по результатам прямого и обратного проходов динамического программирования. По этой карте выделяется устойчивый фрагмент пути выравнивания и используется для расчёта положения кровли целевого интервала.
4. Разработан итеративный алгоритм уточнения положения кровли целевого пласта с использованием данных нескольких опорных скважин, основанный на агрегировании информации по устойчивым фрагментам путей выравнивания и применении устойчивых статистических оценок. Отличительной особенностью предложенной методики является сочетание модифицированного алгоритма динамической трансформации временной шкалы с локальной энергетической интерпретацией результата и итеративным объединением данных от нескольких скважин, что обеспечивает практическую применимость метода в условиях промышленной геонавигации и возможность его интеграции в автоматизированные программные комплексы сопровождения бурения.

### ГЛАВА 3. МАТЕМАТИЧЕСКАЯ МОДЕЛЬ ГРАНИЦ ПРОДУКТИВНОГО ПЛАСТА В ОКРЕСТНОСТИ ГОРИЗОНТАЛЬНОГО СТВОЛА БУРЯЩЕЙСЯ СКВАЖИНЫ

#### 3.1. Алгоритм автоматического анализа сходимости гамма-каротажа при геонавигации

При строительстве скважин после завершения бурения транспортной секции выполняется перезапись гамма-каротажа с целью уточнения глубинной привязки каротажных данных. Корректность совмещения данных перезаписи с ранее зарегистрированными измерениями непосредственно влияет на точность определения положения ствола скважины относительно геологических границ и, как следствие, на качество последующих геонавигационных решений.

В производственной практике данная операция выполняется вручную и требует визуального анализа формы кривых, что делает процесс трудоёмким и чувствительным к субъективному фактору. В рамках настоящей работы разработан и реализован простой и вычислительно эффективный алгоритм автоматизированного поиска интервала сходимости и оценки качества данных перезаписи гамма-каротажа, ориентированный на применение в условиях реального времени. Основная схема данного алгоритма была предложена автором в работе [122].

##### *Постановка задачи*

Пусть заданы две каротажные кривые  $y = y(z) = (y_1, y_2, \dots, y_n)$ ,  $p = p(z) = (p_1, p_2, \dots, p_m)$ , где  $y$  – значения гамма-каротажа, зарегистрированные при бурении транспортной секции,  $p$  – значения гамма-каротажа, полученные в процессе перезаписи,  $z \in \mathbb{R}^1$  – измеренная глубина (MD),  $n, m \in \mathbb{N}$ .

Требуется найти такой интервал кривой  $y$ , который наилучшим образом соответствует интервалу перезаписи  $p$  в заданном диапазоне глубин, предполагая, что между кривыми возможен сдвиг по глубине, но отсутствуют деформации вида растяжения или сжатия.

### *Выбор меры сходства*

В отличие от задач геологической корреляции между различными скважинами, анализ перезаписи каротажа относится к задачам контроля согласованности данных в пределах одного ствола скважины. В данной постановке предполагается, что геологические условия не изменяются, а различия между кривыми обусловлены преимущественно сдвигом по глубине, вызванным погрешностями измерения, растяжением бурильной колонны или неточной привязкой инструмента. Таким образом, в задаче отсутствуют деформации вида сжатия или растяжения каротажных кривых, что принципиально отличает её от корреляции между разрезами разных скважин.

В качестве меры сходства используется коэффициент корреляции Пирсона. Использование корреляции позволяет устойчиво выявлять сдвиг по глубине при отсутствии нелинейных деформаций, что соответствует физической природе рассматриваемой задачи. Применение более сложных методов, допускающих растяжение или сжатие кривых (например, DTW), в данном случае нецелесообразно и может приводить к искажению смысла результата.

Пусть заданы два фрагмента одинаковой длины  $y = (y_1, y_2, \dots, y_l)$ ,  $p = (p_1, p_2, \dots, p_l)$ . Коэффициент корреляции Пирсона вычисляется по формуле:

$$r(y, p) = \frac{\sum_{i=1}^l (y_i - \bar{y})(p_i - \bar{p})}{\sqrt{\sum_{i=1}^l (y_i - \bar{y})^2 \sum_{i=1}^l (p_i - \bar{p})^2}}, \quad (3.1)$$

где  $\bar{y}$  и  $\bar{p}$  – выборочные средние соответствующих интервалов.

### *Приведение данных по глубине*

Поскольку шаг дискретизации по глубине для кривых  $y$  и  $p$  может различаться, для обеспечения корректного сравнения выбирается единый шаг  $\Delta z = \max(\Delta z_y, \Delta z_p)$ , после чего данные приводятся к общей глубинной сетке с шагом  $\Delta z$ .

### *Область поиска интервала сходимости*

Границы поиска интервала внутри основной каротажной кривой  $y$  задаются симметричным окном шириной  $\tau$  относительно интервала перезаписи  $[z_{\text{low}}, z_{\text{high}}] = [z_{p,1} - \tau, z_{p,l} + \tau]$ , где  $z_{p,1}$  и  $z_{p,l}$  – глубины начала и конца интервала перезаписи соответственно.

### *Алгоритм поиска соответствующего интервала*

Поиск интервала сходимости осуществляется следующим образом:

*Шаг 1.* От левой границы интервала поиска выделяется фрагмент кривой  $y$  длины  $l$ .

*Шаг 2.* Вычисляется коэффициент корреляции фрагмента кривой  $y$  с интервалом  $p$ .

*Шаг 3.* Начало фрагмента сдвигается на  $\Delta z$  и алгоритм повторяется до достижения правой границы интервала поиска.

*Шаг 4.* Оптимальное положение начала интервала вычисляется как:

$$j^* = \arg \max_{j \in J} r_j, \quad (3.2)$$

где  $J$  – множество допустимых стартовых индексов в интервале  $[z_{\text{low}}, z_{\text{high}}]$ ,  $r_j$  – значение коэффициента корреляции для интервала, начинающегося в точке  $j$ .

### *Проверка устойчивости решения*

Расчёт выполняется для нескольких длин окон перезаписи. После этого сравниваются найденные положения. Если для разных длин окон максимум корреляции соответствует близким значениям сдвига, результат считается устойчивым. Если оценки расходятся, расчёт повторяется до достижения согласованного результата на нескольких итерациях подряд. После завершения расчёта фиксируются найденный сдвиг между кривыми  $y$  и  $p$  и соответствующее значение меры сходства (3.1).

Следует подчеркнуть, что предлагаемый алгоритм не предназначен для геологической интерпретации и не заменяет методы корреляции разрезов. Его

назначение – оперативный контроль качества и согласованности данных, обеспечивающий корректный переход от транспортной секции к дальнейшим этапам геонавигации. Простота, вычислительная эффективность и отсутствие необходимости в обучении делают алгоритм пригодным для практического применения в условиях реального времени и интеграции в автоматизированные системы геонавигации.

## **3.2. Анализ данных азимутального плотностного каротажа**

### **3.2.1. Постановка задачи**

Основная цель геонавигации в горизонтальной секции заключается в обеспечении максимального охвата целевого интервала за счёт своевременной корректировки траектории бурения. Для этого необходимо оперативно оценивать положение ствола скважины относительно кровли и подошвы продуктивного пласта. Одним из наиболее информативных источников данных для решения данной задачи является азимутальный плотностной каротаж, представляемый в виде развёрнутого двумерного изображения (имиджа).

Геометрия азимутальных измерений и способ их развёртки приводят к тому, что при пересечении стволом границ пластов в имиджах формируются характерные криволинейные структуры. При пересечении стволом скважины породы вниз по напластованию сенсоры последовательно фиксируют изменение свойств породы, формируя паттерн, известный как «грустная улыбка». При пересечении пласта вверх по напластованию порядок реакции сенсоров обратный, что визуально проявляется как «весёлая улыбка» (рисунок 22).

Длина и форма данных паттернов напрямую связаны с углом падения пласта и относительным положением границы, что делает их ключевыми объектами интерпретации. Таким образом, задача анализа азимутального плотностного каротажа может быть сформулирована как задача распознавания и локализации криволинейных структур с последующим извлечением их геометрических характеристик, таких как длина и угол наклона.




Рисунок 22. Механизм образования «улыбок».

### 3.2.2. Формализация задачи в терминах анализа изображений

Рассмотрим изображение азимутального плотностного каротажа, заданное в виде матрицы  $I \in \mathbb{R}^{H \times W}$ , где обозначения соответствуют введенным в главе 1. Обозначим через  $L$  множество геологических границ, пересекаемых стволом скважины. Требуется определить множество ограничивающих прямоугольников  $B = \{b_i\}$ ,  $b_i = (x_i, y_i, w_i, h_i)$ , таких, что каждый прямоугольник  $b_i$  локализует одну границу пласта  $L_i$ .

В рассматриваемой задаче используются следующие упрощения, обусловленные особенностями азимутального каротажа. Горизонтальная координата  $x_i$  фиксирована и, как правило, равна нулю, поскольку граница прослеживается по всем азимутальным секторам. Соответственно, ширина прямоугольника  $w_i$  совпадает с числом секторов  $W$ . Основная неопределённость связана с вертикальным положением границы  $y_i$  и её протяжённостью по глубине, характеризуемой параметром  $h_i$ , который определяется интервалом проявления границы и в данной задаче ограничивается значениями порядка 20 м.

В отличие от стандартных задач детекции объектов в компьютерном зрении, где объекты могут иметь произвольное положение и масштаб, в рассматриваемой задаче объекты имеют выраженную анизотропную структуру: они протяжённы по

азимутальному направлению и локализованы по глубине. Это делает неэффективным прямое применение универсальных детекционных моделей.

В связи с этим в работе предлагается математическая модель распознавания геологических границ на азимутальных изображениях, согласованная с введённой формализацией задачи и учитывающая её специфические ограничения. Модель реализуется в виде последовательности этапов обработки данных, включающей предобработку, выделение кандидатов на границы и их последующую классификацию. Основные положения данного подхода к математическому моделированию горизонтальной секции бурящейся скважины по данным азимутального плотностного каротажа представлены в работе [123].

Практический анализ данных азимутального каротажа показывает, что исходные изображения характеризуются:

- выраженной нестационарностью контраста,
- наличием шумов и артефактов измерений,
- фрагментарностью и разрывностью границ,
- вариативностью формы паттернов «улыбок».

Прямое обучение нейросетевой модели end-to-end для детекции границ в таких условиях требует большого объёма размеченных данных и зачастую приводит к нестабильным результатам. В связи с этим в работе выбран гибридный подход, сочетающий:

1. нейросетевое восстановление и стабилизацию структуры изображения,
2. классические алгоритмы выделения контуров,
3. последующую классификацию кандидатов на основе сверточной модели.

Такой подход позволяет разделить задачу на этапы с чётким физическим и алгоритмическим смыслом, повысить интерпретируемость решения и снизить требования к объёму обучающей выборки.

### 3.2.3. Обучение сверточного автоэнкодера для восстановления структуры изображения

Автоэнкодер – это разновидность нейронной сети, предназначенная для обучения эффективного представления данных в задачах обучения без учителя. Идея автоэнкодера заключается в том, чтобы обучиться восстанавливать входные данные после их сжатия через внутреннее представление (embedding или латентное пространство). Структурно автоэнкодер состоит из двух взаимосвязанных частей – энкодера и декодера. Энкодер осуществляет отображение входных данных в латентное пространство пониженной размерности, а декодер выполняет обратное преобразование, восстанавливая данные из латентного представления.

В настоящей работе автоэнкодер используется в качестве структурного фильтра, направленного на подавление шумов и сохранение геометрии контрастных границ, соответствующих геологическим неоднородностям. Это позволяет стабилизировать форму паттернов «улыбок» перед последующими этапами контурной фильтрации и классификации.

Энкодер представляет собой параметризованное отображение  $E: \mathbb{R}^{H \times W} \rightarrow \mathbb{R}^d$  с параметрами  $\theta_e$ , где  $d \ll H \cdot W$ , которое преобразует входное изображение в латентное представление меньшей размерности:

$$z = E(I; \theta_e). \quad (3.3)$$

Декодер представляет собой отображение  $D: \mathbb{R}^d \rightarrow \mathbb{R}^{H \times W}$  с параметрами  $\theta_d$ , которое восстанавливает изображение из латентного представления:

$$\hat{I} = D(z; \theta_d) = D(E(I; \theta_e); \theta_d). \quad (3.4)$$

Латентный вектор  $z \in \mathbb{R}^d$  представляет собой компактное описание входного изображения, сохраняющее его существенные структурные характеристики.

Архитектурно сверточный автоэнкодер реализуется в виде последовательности сверточных слоёв с понижением пространственного разрешения на этапе кодирования и симметричной структуры декодера, восстанавливающей изображение до исходного размера. Типовая схема такой архитектуры приведена на рисунке 23 и иллюстрирует общий принцип построения

сверточного автоэнкодера. Конкретные параметры сети (количество слоёв, размерность латентного пространства, число фильтров) подбираются эмпирически и могут варьироваться в зависимости от характеристик исходных данных.




Рисунок 23. Пример архитектуры сверточного автоэнкодера.

Обучение модели требует задания функции потерь  $\mathcal{L}(I, \hat{I})$ , определяющей критерий близости между исходным изображением  $I$  и его реконструкцией  $\hat{I}$ . В задачах восстановления изображений традиционно используются покомпонентные меры ошибки, например среднеквадратичное или среднее абсолютное отклонение. Однако для азимутальных каротажных изображений такого критерия недостаточно, поскольку он ориентирован преимущественно на совпадение интенсивностей и не учитывает пространственную организацию изображения. Специфика рассматриваемых данных состоит в том, что информативные объекты («улыбки») представлены не отдельными локальными пиксельными особенностями, а протяжёнными контрастными структурами, имеющими характерную криволинейную форму. Поэтому функция потерь должна одновременно учитывать несколько свойств реконструируемого изображения:

1. близость значений интенсивности;
2. сохранение локальной и многомасштабной структуры;
3. сохранение выраженных границ;
4. согласование крупномасштабной геометрии изображения.

С учётом указанных требований в работе задается комбинированная функция потерь:

$$\mathcal{L}(I, \hat{I}) = \lambda_1 \mathcal{L}_{rec}(I, \hat{I}) + \lambda_2 \mathcal{L}_{SSIM}(I, \hat{I}) + \lambda_3 \mathcal{L}_g(I, \hat{I}) + \lambda_4 \mathcal{L}_{blur}(I, \hat{I}), \quad (3.5)$$

где  $\lambda_1, \lambda_2, \lambda_3, \lambda_4 \geq 0$  – весовые коэффициенты, определяющие вклад соответствующих компонент, являются гиперпараметрами модели и подбираются в процессе обучения.

### *Компонента восстановления интенсивности*

Компонента  $\mathcal{L}_{rec}$  отвечает за согласование исходного и восстановленного изображений по интенсивности и определяется как среднее абсолютное отклонение ( $L_1$ -норма):

$$\mathcal{L}_{rec}(I, \hat{I}) = \frac{1}{HW} \sum_{x,y} |I(x, y) - \hat{I}(x, y)|, \quad (3.6)$$

где  $H$  и  $W$  – высота и ширина изображения соответственно. Использование  $L_1$ -нормы вместо квадратичной связано с тем, что она в меньшей степени чувствительна к локальным выбросам и не приводит к избыточному сглаживанию реконструкции.

### *Структурная компонента*

Для учёта структурного сходства изображения используется мера сходства SSIM [116]. Пусть  $\omega$  – нормированное гауссово окно размера  $k \times k$ , используемое для вычисления локальных статистик изображения. Символом  $*$  далее обозначена операция двумерной свёртки изображения с окном  $\omega$ . В результате свёртки вычисляются локальные статистики яркости и дисперсии внутри рассматриваемого окна. Построим локальные статистики по окну  $\omega$ :

$$\begin{aligned} \mu_I &= \omega * I, \mu_{\hat{I}} = \omega * \hat{I} \\ \sigma_I^2 &= \omega * I^2 - \mu_I^2, \sigma_{\hat{I}}^2 = \omega * \hat{I}^2 - \mu_{\hat{I}}^2 \\ \sigma_{I\hat{I}} &= \omega * I\hat{I} - \mu_I \mu_{\hat{I}}, \end{aligned} \quad (3.7)$$

где  $\mu_I, \mu_{\hat{I}}$  – локальные средние значения интенсивности,  $\sigma_I^2, \sigma_{\hat{I}}^2$  – локальные дисперсии,  $\sigma_{I\hat{I}}$  – локальная ковариация сигналов. Все величины вычисляются внутри окна  $\omega$  и представляют собой скалярные характеристики локальной области изображения.

Локальная структурная мера сходства определяется выражением

$$SSIM = \frac{(2\mu_I\mu_{\hat{I}} + C_1)(2\sigma_{I\hat{I}} + C_2)}{(\mu_I^2 + \mu_{\hat{I}}^2 + C_1)(\sigma_I^2 + \sigma_{\hat{I}}^2 + C_2)}, \quad (3.8)$$

где  $C_1 = (k_1L)^2$  и  $C_2 = (k_2L)^2$  – константы, которые вводятся для обеспечения численной устойчивости при малых значениях дисперсий и средних,  $L$  – динамический диапазон значений изображения (например,  $L = 255$  для 8-битных изображений),  $k_1$  и  $k_2$  – безразмерные коэффициенты (обычно принимаются значения  $k_1 = 0.01, k_2 = 0.03$ ).

Таким образом, структурная мера сходства определяется как средняя мера сходства по всем окнам:

$$\mathcal{L}_{SSIM}(I, \hat{I}) = 1 - \frac{1}{HW} \sum_{x,y} SSIM_{xy}(I, \hat{I}). \quad (3.9)$$

### Градиентная компонента

Для сохранения выраженных границ вводится градиентная компонента. Пусть  $S(I)$  обозначает карту модуля градиента изображения, вычисляемую с использованием операторов Собеля [124]

$$S_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}, S_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad (3.10)$$

Градиенты изображений по горизонтальному  $x$  и вертикальному  $y$  направлениям вычисляются посредством свёртки изображения с соответствующими ядрами:

$$G_x = S_x * I, G_y = S_y * I, \quad \hat{G}_x = S_x * \hat{I}, \hat{G}_y = S_y * \hat{I}, \quad (3.11)$$

где символ  $*$  обозначает операцию двумерной свёртки изображения с ядром фильтра.

Для учёта того, что не все градиентные структуры изображения являются одинаково информативными, вводится бинарная маска сильных границ  $M(x, y)$ , позволяющая учитывать только наиболее выраженные градиенты:

$$M(x, y) = \begin{cases} 1, & S(I) \geq q_p(S(I)), \\ 0, & \text{иначе,} \end{cases} \quad (3.12)$$

где  $q_p(S(I))$  – квантиль уровня  $p$  распределения величины градиента, а  $S(I) = |G_x| + |G_y|$  – модуль градиента изображения.

Тогда компонента функции потерь, основанная на различии градиентов изображений, может быть записана в виде

$$\mathcal{L}_g(I, \hat{I}) = \frac{1}{\sum_{x,y} M(x, y)} \sum_{x,y} M(x, y) (|G_x(x, y) - \hat{G}_x(x, y)| + |G_y(x, y) - \hat{G}_y(x, y)|), \quad (3.13)$$

где  $H$  и  $W$  – высота и ширина изображения соответственно,  $(x, y)$  – координаты пикселя изображения,  $G_x(x, y)$  и  $G_y(x, y)$  – значения горизонтального и вертикального градиентов изображения в точке  $(x, y)$ . Эта компонента штрафует расхождение градиентов исходного и восстановленного изображений. Она нужна для сохранения контрастных локальных границ.

#### *Сглаживающая компонента*

Для согласования низкочастотной составляющей изображения вводится компонента, сравнивающая сглаженные версии исходного и восстановленного изображений:

$$L_{blur}(I, \hat{I}) = \frac{1}{HW} \sum_{x,y} |B(I)(x, y) - B(\hat{I})(x, y)|, \quad (3.14)$$

где  $B(\cdot)$  – линейный сглаживающий оператор. Данная компонента необходима для сохранения крупномасштабной геометрии изображения и уменьшения чувствительности функционала к мелкомасштабным флуктуациям.

Таким образом, функционал (3.5) объединяет четыре взаимодополняющих критерия, что обеспечивает согласование реконструкции с исходным изображением одновременно в пространстве интенсивностей, локальных статистик, градиентов и низкочастотных составляющих. Такой подход позволяет

обеспечить баланс между сохранением глобальной геометрии изображения и точностью восстановления локальных границ, что делает автоэнкодер эффективным инструментом предварительной фильтрации азимутальных данных.

Пусть задана выборка изображений азимутального каротажа  $\{I^{(i)}\}_{i=1}^N$ , где  $N$  – число объектов. Обучение модели заключается в минимизации функции потерь по параметрам модели  $\theta = (\theta_e, \theta_d)$ , при этом оптимальные параметры определяются как решение задачи

$$\theta^* = \underset{\theta}{\operatorname{argmin}} \frac{1}{N} \sum_{i=1}^N \mathcal{L}(I^{(i)}, D(E(I^{(i)}; \theta_e); \theta_d)). \quad (3.15)$$

Обучение автоэнкодера выполняется в режиме обучения без учителя на наборе изображений азимутального плотностного каротажа без использования разметки геологических границ. Оптимизация выполняется с использованием алгоритма Adam (Adaptive Moment Estimation) [118], основанного на стохастической аппроксимации градиента по мини-пакетам обучающих данных. На каждом шаге оптимизации  $t$  используется подвыборка  $\{I^{(i)}\}_{i \in \mathcal{B}_t}$ , где  $\mathcal{B}_t \subset \{1, \dots, N\}$  – множество индексов мини-пакета размера  $B \ll N$ , а обновление параметров модели осуществляется на основе градиента функции потерь, вычисленного по текущему мини-пакету  $\mathcal{B}_t$ . Градиент функции потерь по параметрам модели определяется как

$$g_t = \nabla_{\theta} \left( \frac{1}{B} \sum_{i \in \mathcal{B}_t} L(I^{(i)}, D(E(I^{(i)}; \theta_e); \theta_d)) \right), \quad (3.16)$$

где  $g_t \in \mathbb{R}^p$  – вектор градиентов,  $p = p_e + p_d$  – общее число параметров модели.

Алгоритм Adam использует экспоненциально сглаженные оценки первого и второго моментов градиента:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t, \quad v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2, \quad (3.17)$$

где  $m_t \in \mathbb{R}^p$  – оценка первого момента,  $v_t \in \mathbb{R}^p$  – оценка второго момента,  $\beta_1, \beta_2$  – коэффициенты экспоненциального сглаживания, определяющие степень учёта предыдущих значений градиента и его квадрата. Коэффициенты  $\beta_1$  и  $\beta_2$  задают

степень сглаживания оценок градиента и его квадрата. В расчётах использованы значения  $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$ .

При нулевой инициализации  $m_t$  и  $v_t$  первые оценки моментов занижены. Поэтому перед обновлением параметров используются поправки:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}, \quad \hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (3.18)$$

и само обновление параметров модели выполняется по правилу:

$$\theta_{t+1} = \theta_t - \eta \cdot \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \varepsilon}, \quad (3.19)$$

где  $\eta > 0$  – шаг обучения,  $\varepsilon > 0$  – малое число для предотвращения деления на ноль.

В формулах Adam квадрат, корень и деление применяются покомпонентно. Поэтому для разных параметров модели фактически используются разные масштабы обновления.

Оптимизатор Adam выбран из-за особенностей обучающей выборки: изображения азимутального каротажа содержат участки с разным контрастом и в таких данных вклад отдельных пикселей и градиентных компонент может заметно различаться по масштабу. За счёт оценок первого и второго моментов Adam изменяет масштаб обновления параметров в ходе обучения, поэтому он удобнее простого градиентного спуска для обучения автоэнкодера на мини-пакетах.

После автоэнкодера получается реконструированное изображение, в котором часть шума подавляется, а контрастные переходы сохраняются (рисунок 24). Это снижает число шумовых контуров на следующем этапе и облегчает отбор кандидатов типа «улыбка».




Рисунок 24. Снижение шума и усиление структур автоэнкодером.

### 3.2.4. Контурная фильтрация

После восстановления автоэнкодером изображение передаётся на этап контурной фильтрации. На этом этапе ищутся протяжённые контрастные переходы, которые могут соответствовать геологическим границам.

Сначала реконструированное изображение  $\hat{I}$  бинаризуется. Порог выбирается методом Оцу [125] на основе статистики интенсивностей изображения. Такой выбор удобен для азимутальных изображений, так как контраст и уровень шума заметно меняются по глубине и фиксированный порог часто даёт лишние области или пропускает слабые границы (рисунок 25). После выбора порога получается бинарная маска  $\hat{T}$ :

$$\hat{T} = Otsu(\hat{I}), \quad (3.20)$$

где каждый элемент  $\hat{t}$  матрицы  $\hat{T}$  вычисляется по правилу:

$$\hat{t} = \begin{cases} 0, & \hat{I} \leq t, \\ 1, & \hat{I} > t, \end{cases} \quad (3.21)$$

где  $t$  – порог бинаризации.

Порог  $t^*$  выбирается так, чтобы разделение пикселей на два класса давало максимальную межклассовую дисперсию:

$$t^* = \arg \max_t \omega_0(t) \omega_1(t) [\mu_0(t) - \mu_1(t)]^2, \quad (3.22)$$

где  $\omega_0(t), \omega_1(t)$  обозначают доли пикселей двух классов, а  $\mu_0(t), \mu_1(t)$  – средние значения яркости в этих классах.




Рисунок 25. Бинаризация методом Оцу.

На следующем этапе для выделения границ на бинаризованном изображении  $\hat{T}$  применяется детектор Канни [79]:

$$\hat{E} = \text{Canny}(\hat{T}), \quad (3.23)$$

обеспечивающий устойчивое выделение протяжённых и непрерывных контуров за счёт сочетания сглаживания, подавления немаксимумов и двойной пороговой фильтрации.

Алгоритм Канни включает следующие этапы:

- сглаживание изображения гауссовым фильтром;
- вычисление градиентов по направлениям  $x$  и  $y$ ;
- расчёт модуля и направления градиента;
- подавление немаксимумов;
- двойную пороговую фильтрацию и трассировку по гистерезису.

Использование детектора Канни позволяет получить карту границ, устойчивую к шуму и локальным выбросам, при этом на данном этапе допускается избыточное количество кандидатов, поскольку окончательное решение о принадлежности структуры к классу «улыбок» принимается на последующих этапах (рисунок 26).




Рисунок 26. Выделение границ методом Канни.

Для перехода от пиксельного представления к объектному уровню на карте границ  $\hat{E}$  применяется алгоритм трассировки контуров [126], позволяющий извлечь замкнутые и иерархически вложенные контуры (рисунок 27). В результате формируется множество контуров  $C = \{c_1, \dots, c_n\}$ , где каждый контур  $c_i$  задаётся последовательностью координат, описывающих границу объекта.




Рисунок 27. Извлечение связанных контуров.

С целью исключения шумовых и геометрически некорректных кандидатов из множества  $C$  отбираются только те контуры, которые пересекают крайние азимутальные сектора изображения, то есть содержат пиксели с индексами, соответствующими границам по оси  $W$  (в частности, сектора с индексами 0 и  $W - 1$ ). Это условие отражает физическую природу искомых структур, которые, как правило, непрерывно прослеживаются по всем азимутальным секторам.

Для каждого отобранного контура  $c_i$  строится минимальный ограничивающий прямоугольник (bounding box)  $b_i = (x_i, y_i, w_i, h_i)$ ,  $i = 1, \dots, N_c$ , где  $N_c$  – число отобранных контуров (рисунок 28). Полученные прямоугольники далее подаются на вход классификатору.




Рисунок 28. Локализация кандидатов.

Таким образом, задача переводится из пространства отдельных пикселей в пространство объектов, что существенно снижает размерность задачи и повышает устойчивость последующего анализа. Полученное множество ограничивающих прямоугольников содержит все потенциальные кандидаты на геологические границы с характерной синусоидальной формой («улыбки»).

Для отбора только релевантных объектов используется сверточный бинарный классификатор, предварительно обученный на размеченной выборке. Для каждого ограничивающего прямоугольника  $b_i$  классификатор вычисляет оценку принадлежности классу «улыбок»:

$$B^* = \{ b_i \mid f_\phi(b_i) > \omega \}, \quad (3.24)$$

где  $\omega$  – порог отбора кандидатов.

### 3.2.5. Обучение сверточного бинарного классификатора

После контурной фильтрации каждый найденный контур описывается ограничивающим прямоугольником. Но не все контуры соответствуют реальным границам пластов, часть из них – шумовые контуры или артефакты записи. Сначала для того, чтобы отсеять таких ложных кандидатов рассматривались экспертные правила на геометрию контура и размеры ограничивающего прямоугольника. Но этот подход показал ограниченную устойчивость при изменении геологических условий, уровня шума и параметров каротажного инструмента, а также требовал ручной подстройки порогов для различных скважин и интервалов. В связи с этим в работе принят подход, основанный на обучении

сверточного бинарного классификатора, способного автоматически различать фрагменты изображений, содержащие паттерны «улыбок», и фоновые участки.

Пусть задано множество размеченных участков изображений (патчей)  $\{(p^{(i)}, q^{(i)})\}_{i=1}^N$ , где  $p^{(i)} \subset [H \times W]$  – вырезанный участок изображения, соответствующий ограничивающему прямоугольнику, а  $q^{(i)} \in \{0,1\}$  – бинарная метка, принимающая значение 1 для паттернов «улыбок» и 0 для фоновых фрагментов.

Цель сверточного классификатора  $f_\varphi(p)$  – оценить вероятность принадлежности фрагмента изображению с геологической границей

$$\hat{q} = f_\varphi(p) \in (0,1). \quad (3.25)$$

Параметры модели свёрточного классификатора настраиваются по размеченным фрагментам изображений. В качестве функции потерь используется бинарная кросс-энтропия:

$$L_{BCE}(q, \hat{q}) = -q \cdot \log \hat{q} - (1 - q) \cdot \log(1 - \hat{q}), \quad (3.26)$$

а оптимизация выполняется алгоритмом Adam:

$$\varphi^* = \operatorname{argmin}_{\varphi} \frac{1}{N} \sum_{i=1}^N L_{BCE}(q^{(i)}, f_\varphi(p^{(i)})), \quad (3.27)$$

где  $\varphi$  – параметры классификатора,  $p^{(i)}$  – фрагмент изображения,  $q^{(i)} \in \{0,1\}$  – метка класса,  $N$  – размер обучающей выборки.

Обучение выполняется по мини-пакетам размеченных патчей. Это удобно в данной задаче, поскольку число размеченных примеров ограничено, и кандидаты меняются от окна к окну. Отдельный классификатор используется уже после выделения кандидатов. Сначала алгоритм находит возможные контуры, а затем модель отбрасывает фрагменты, похожие на шум или артефакты записи. Такое разделение упрощает проверку ошибок, так как можно отдельно анализировать пропущенные кандидаты и ошибки классификации.

После применения классификатора остаётся подмножество прямоугольников из (3.24), для которых вероятность класса «улыбка» превышает заданный порог (рисунок 29). Эти «улыбки» далее используются для извлечения

количественных геологических характеристик, включая длину «улыбки» и оценку угла залегания продуктивного пласта.




Рисунок 29. Классификация кандидатов на улыбки и фон.

Несмотря на активное развитие end-to-end подходов к детекции и сегментации объектов на изображениях (YOLO-подобные модели, fully convolutional networks, U-Net, DeepLab и др.), в настоящей работе выбран модульный подход, основанный на последовательном выделении кандидатов, их геометрической фильтрации и последующей классификации. Выбор такой архитектуры обусловлен рядом факторов, связанных со спецификой данных азимутального каротажа и практическими требованиями геонавигации. Во-первых, end-to-end модели детекции и сегментации требуют большого объёма высококачественной пиксельной или объектной разметки. В условиях промышленной геонавигации разметка «улыбок» является трудоёмкой, субъективной и плохо масштабируемой задачей, поскольку границы пластов часто выражены неявно, частично перекрываются шумом и не имеют однозначной геометрической формы. Во-вторых, детекционные и сегментационные сети чувствительны к доменному сдвигу, связанному с изменением геологии, конфигурации измеряющего прибора, числа азимутальных секторов и уровня шума. Это приводит к тому, при переносе модели между скважинами и месторождениями необходимо их постоянное дообучение. В-третьих, в задачах геонавигации важна интерпретируемость промежуточных результатов и возможность локального контроля качества решений. End-to-end модели не

позволяют явно анализировать, на каком этапе произошла ошибка, что затрудняет промышленную эксплуатацию и сопровождение алгоритма.

Предложенный в работе модульный подход сочетает преимущества классической обработки изображений и методов машинного обучения: предварительная фильтрация и выделение контуров обеспечивают физически интерпретируемое описание кандидатов, а сверточный классификатор адаптивно решает задачу распознавания паттернов. Такая архитектура позволяет снизить требования к разметке данных, повысить устойчивость к шуму и геологической неоднородности, а также обеспечить гибкую настройку и интеграцию алгоритма в существующие рабочие процессы геонавигации.

### **Основные выводы к главе 3**

1. Для этапа перезаписи каротажа предложен алгоритм автоматического анализа сходимости данных гамма-каротажа, основанный на корреляционном сопоставлении интервалов. Формализация задачи в виде поиска оптимального сдвига по глубине и использование коэффициента корреляции Пирсона позволяют надёжно определять интервал сходимости, контролировать корректность привязки перезаписи и снижать влияние человеческого фактора при оперативной интерпретации данных.
2. Для анализа азимутального плотностного каротажа в горизонтальной секции данные представлены в виде двумерных имиджей, на которых геологические границы рассматриваются как протяжённые криволинейные структуры. Для предварительной обработки используется сверточный автоэнкодер с комбинированной функцией потерь. Он снижает влияние мелкомасштабного шума и сохраняет контрастные элементы изображения, которые далее используются при выделении кандидатов на границы.
3. После восстановления изображения выполняется контурная фильтрация: протяжённые контуры описываются ограничивающими прямоугольниками и рассматриваются как кандидаты на границы типа «улыбка». Для отбора таких кандидатов используется сверточный бинарный классификатор. Такая схема

позволяет отделять геологически значимые паттерны от шумовых контуров, артефактов записи и локальных текстурных неоднородностей.

4. Предложенная схема не является end-to-end моделью. Обработка разделена на отдельные этапы: восстановление изображения, выделение контуров, построение кандидатов и их классификацию. Это делает результат более интерпретируемым и на каждом этапе можно проверить, какие структуры были выделены и почему часть кандидатов была отброшена. Такой формат удобен для последующей интеграции в программный модуль поддержки геонавигации.

## **ГЛАВА 4. АПРОБАЦИЯ И ТЕСТИРОВАНИЕ РАЗРАБОТАННЫХ РЕШЕНИЙ**

Разработанные в настоящей работе модели и методики реализованы как отдельные модули программного обеспечения геонавигации и апробированы на промышленных данных. Апробация проводилась на реальных каротажных и геонавигационных данных, зарегистрированных в процессе бурения транспортных и горизонтальных секций, и включала как качественный анализ (разбор типовых примеров и ошибок), так и количественную оценку точности (метрики, распределения ошибок, анализ влияющих факторов).

Тестирование было организовано в соответствии с реальным производственным процессом геонавигации:

- (1) уточнение положения кровли целевого интервала в транспортной секции по данным межскважинной корреляции,
- (2) контроль перезаписи,
- (3) автоматическое выделение границ пласта по азимутальному плотностному каротажу в горизонтальной секции с последующим вычислением параметров структуры (в частности, угла залегания).

Исходные данные включали:

- каротажные кривые гамма-каротажа (ГК) в транспортной секции,
- данные перезаписи каротажа после бурения транспортной секции,
- разметку маркеров пластопересечений в опорных скважинах и фактические положения целевых геологических границ по результатам бурения,
- матрицы азимутального плотностного каротажа в горизонтальной секции (имидж-данные) с экспертной разметкой паттернов границ («улыбок»).

## 4.1. Апробация методики уточнения положения кровли целевого пласта в транспортной секции

### 4.1.1. Общая логика апробации и критерии успешности

Разработанная в главе 2 методика уточнения положения кровли целевого пласта основана на трёх взаимосвязанных элементах: модифицированном алгоритме динамической трансформации временной шкалы (Subsequence-DTW), введении локальной энергетической интерпретации результата выравнивания с выделением устойчивого фрагмента пути выравнивания и итеративном агрегировании оценок по группе опорных скважин.

Методика опирается на межскважинную корреляцию интервалов каротажа между разбуриваемой и опорными скважинами. Важным практическим аспектом является то, что реальная геологическая картина зачастую представляет собой сочетание структурного фактора и литологической невыдержанности. В частности, изменение истинной мощности пласта в разбуриваемой скважине может быть зафиксировано только по факту вскрытия подошвы, а надёжно предсказать степень изменения мощности исключительно по межскважинной корреляции зачастую невозможно.

В отличие от задач постфактум-анализа, в условиях промышленной геонавигации данные разбуриваемой скважины поступают последовательно, по мере углубления ствола. Это означает, что прогноз положения кровли целевого интервала формируется в условиях неполной информации, причём объём доступных данных непрерывно увеличивается. В связи с этим апробация методики выполнялась в режиме, имитирующем реальный процесс бурения. Для каждой из 20 тестируемых скважин моделировался последовательный прирост доступного интервала каротажа с шагом порядка 100 м по глубине. На каждом этапе использовалось только подмножество данных  $\{y_i^{(H)} \mid z_i \leq z_{\max}\}$ , соответствующее текущей глубине бурения. При этом запуск алгоритма уточнения положения кровли целевого интервала выполнялся не на каждом шаге прироста, а только при достижении глубины, достаточной для сопоставления очередной пары маркеров. В

качестве такого условия использовалось достижение глубины, соответствующей минимальному значению глубины нижнего маркера данной пары среди всех опорных скважин. Это обеспечивает наличие в данных горизонтальной скважины интервала, сопоставимого с рассматриваемым интервалом между маркерами в опорных скважинах.

Следует подчеркнуть, что в рассматриваемой методике уточнение прогноза связано не с увеличением длины сопоставляемого интервала, а с последовательным включением новых геологических интервалов. Для каждого такого интервала независимо выполняется корреляция с опорными скважинами, выделяется соответствующий устойчивый фрагмент пути выравнивания (2.18), после чего вычисляется оценка положения кровли.

Таким образом, при каждом запуске алгоритма использовались только те данные, которые были бы реально доступны в процессе бурения, и формировалась последовательность оценок положения кровли (2.21). Такая схема тестирования принципиально важна для проверки применимости метода в реальном времени, поскольку позволяет учитывать ограничения доступности данных. Критерием количественной оценки служила абсолютная метрическая ошибка прогноза положения кровли относительно фактического значения, определённого по результатам вскрытия пласта.

#### 4.1.2. Пример работы методики

Для иллюстрации работы предложенной методики на рисунках ниже приведён пример сопоставления интервалов гамма-каротажа для двух последовательных пар маркеров:  $(m_1, m_2)$  и  $(m_2, m_3)$  для трех опорных скважин  $w_1, w_2, w_3$ . Для каждой пары маркеров выполняется сопоставление интервала в разбуриваемой скважине с соответствующими интервалами во всех доступных опорных скважинах.

На рисунках 30–32 представлены результаты сопоставления для первой пары маркеров  $(m_1, m_2)$  с опорными скважинами. Серыми линиями показан оптимальный путь выравнивания, а выделенный зеленым фрагмент соответствует

устойчивому участку с минимальной средней энергией и высокой локальной контрастностью сигнала.




Рисунок 30. Результат сопоставления интервалов между маркерами  $(m_1, m_2)$  по опорной скважине  $w_1$ .




Рисунок 31. Результат сопоставления интервалов между маркерами  $(m_1, m_2)$  по опорной скважине  $w_2$ .




Рисунок 32. Результат сопоставления интервалов между маркерами  $(m_1, m_2)$  по опорной скважине  $w_3$ .

Аналогично, на рисунках 33–35 приведены результаты сопоставления для второй пары маркеров  $(m_2, m_3)$ .




Рисунок 33. Результат сопоставления интервалов между маркерами ( $m_2, m_3$ ) по опорной скважине  $w_1$ .




Рисунок 34. Результат сопоставления интервалов между маркерами ( $m_2, m_3$ ) по опорной скважине  $w_2$ .




Рисунок 35. Результат сопоставления интервалов между маркерами ( $m_2, m_3$ ) по опорной скважине  $w_3$ .

Результатом каждого сопоставления интервалов являются абсолютные глубины устойчивого фрагмента пути выравнивания. Далее для каждой опорной скважины вычисляется расстояние от положения устойчивого фрагмента пути выравнивания до кровли целевого интервала (2.19). Затем полученное расстояние переносится на соответствующий устойчивый интервал в разбуриваемой скважине (2.20). Результаты расчётов для первой и второй пары маркеров приведены в таблицах 1 и 2 соответственно. В таблицах указаны:

- границы устойчивого интервала в разбуриваемой и опорной скважинах (верх и низ),
- глубина кровли в опорной скважине,
- вычисленное расстояние до кровли,
- оценка положения кровли в разбуриваемой скважине.

Таблица 1. Результаты расчёта положения кровли целевого интервала в разбуриваемой скважине по данным сопоставления с опорными скважинами (пара маркеров ( $m_1, m_2$ )).

| № опорной скважины | АО в разбуриваемой скважине (верх) | АО в опорной скважине (верх) | АО в разбуриваемой скважине (низ) | АО в опорной скважине (низ) | АО кровли ЦИ в опорной скважине | расстояние до кровли ЦИ в опорной скважине | Оценка положения кровли ЦИ в разбуриваемой скважине |
|--------------------|------------------------------------|------------------------------|-----------------------------------|-----------------------------|---------------------------------|--------------------------------------------|-----------------------------------------------------|
| $w_1$              | -2624,2                            | -2619,8                      | -2634,2                           | -2630,0                     | -2738,1                         | 108,1                                      | -2742,3                                             |
| $w_2$              | -2623,2                            | -2629,0                      | -2634,4                           | -2639,6                     | -2745,0                         | 105,4                                      | -2739,8                                             |
| $w_3$              | -2622,6                            | -2610,8                      | -2634,8                           | -2622,6                     | -2729,0                         | 106,4                                      | -2741,2                                             |

Таблица 2. Результаты расчёта положения кровли целевого интервала в разбуриваемой скважине по данным сопоставления с опорными скважинами (пара маркеров ( $m_2, m_3$ )).

| № опорной скважины | АО в разбуриваемой скважине (верх) | АО в опорной скважине (верх) | АО в разбуриваемой скважине (низ) | АО в опорной скважине (низ) | АО кровли ЦИ в опорной скважине | расстояние до кровли ЦИ в опорной скважине | Оценка положения кровли ЦИ в разбуриваемой скважине |
|--------------------|------------------------------------|------------------------------|-----------------------------------|-----------------------------|---------------------------------|--------------------------------------------|-----------------------------------------------------|
| $w_1$              | -2706,0                            | -2703,4                      | -2710,6                           | -2708,4                     | -2738,1                         | 34,7                                       | -2740,7                                             |
| $w_2$              | -2706,4                            | -2713,8                      | -2710,4                           | -2717,4                     | -2745,0                         | 31,2                                       | -2737,6                                             |
| $w_3$              | -2708,4                            | -2698,4                      | -2712,4                           | -2703,2                     | -2729,0                         | 30,06                                      | -2739,0                                             |

Таким образом, для каждой пары маркеров и каждой опорной скважины получается отдельная оценка положения кровли. Поскольку эти оценки могут отличаться вследствие геологических вариаций и погрешностей сопоставления, итоговая оценка положения кровли для каждой пары маркеров определяется как медиана по опорным скважинам (2.21). Использование медианы позволяет снизить

влияние выбросов и некорректных сопоставлений для отдельных опорных скважин и получить более устойчивую оценку.

В рассматриваемом примере фактическое положение кровли целевого интервала в разбуриваемой скважине составляет -2738,5 м. Для первой пары маркеров  $(m_1, m_2)$  медианная оценка составляет  $\hat{z}^{(1)}(w_H, m_2) = -2741,2$  м, отклонение прогноза от фактического положения кровли – 2,7 метров. Для второй пары маркеров  $(m_2, m_3)$ :  $\hat{z}^{(1)}(w_H, m_3) = -2738,2$  м, отклонение – 0,3 м.

Анализ результатов тестирования предложенного алгоритма на данных 20 скважин различных месторождений показывает, что использование устойчивого фрагмента выравнивания в сочетании с агрегированием по нескольким опорным скважинам обеспечивает получение оценок положения кровли целевого интервала с высокой точностью даже в условиях локальных искажений и различий между скважинами. Средняя величина отклонения прогнозного положения кровли от фактического на тестовых скважинах составила около 3 м, что соответствует требуемой инженерной точности сопровождения бурения транспортной секции. Наблюдаемые единичные выбросы обусловлены, как правило, выраженной геологической невыдержанностью разреза.

#### **4.2. Тестирование алгоритма анализа перезаписи гамма-каротажа**

Алгоритм автоматического анализа сходимости и качества данных перезаписи гамма-каротажа предназначен для решения практической задачи корректной привязки повторной записи каротажа после бурения транспортной секции. Некорректная привязка перезаписи приводит к систематическому смещению глубинной шкалы, что влияет на положение ствола в пласте и на последующие этапы геонавигации. В связи с этим разработанный алгоритм рассматривается как важный связующий элемент между этапом уточнения положения кровли в транспортной секции и моделированием границ в горизонтальной секции.

### 4.2.1. Постановка эксперимента

Тестирование проводилось на данных 19 скважин с различными характеристиками формы каротажной кривой и качеством записи. В выборке присутствовали как интервалы с выраженной пикообразной структурой, так и участки с невыраженной или сглаженной формой сигнала. Дополнительно учитывались случаи наличия пропущенных участков и коротких интервалов перезаписи.

Для каждой скважины алгоритм запускался при различной длине интервала перезаписи (от 10 до 50 метров либо до максимально доступной длины перезаписи с шагом 5 метров). Оценивались:

- величина коэффициента корреляции Пирсона;
- величина вычисленного сдвига по глубине;
- стабильность результата при увеличении длины интервала.

Результат считался корректным, если найденный интервал сохранялся при увеличении длины окна, при этом вычисленный сдвиг соответствовал экспертной оценке, а коэффициент корреляции превышал эмпирически установленный порог.

### 4.2.2. Общая оценка результатов

Результаты тестирования показывают, что выраженность геологического репера является ключевым для успешности автоматического сопоставления перезаписи и основного каротажа. Для интервалов с выраженными реперами (68 % выборки) наблюдались устойчивые значения коэффициента корреляции в диапазоне 0,8–0,98 и стабильное определение сдвига, а доля успешных решений составила 86 %. Это можно объяснить тем, что коэффициент корреляции Пирсона чувствителен к наличию контрастных экстремумов и обеспечивает однозначный максимум при совпадении характерных пиков. В случае же невыраженной или сглаженной формы сигнала корреляция снижается, а положение максимума становится менее устойчивым, следовательно, при близкой к линейной структуре сигнала информативность коэффициента корреляции уменьшается, что приводит к росту неопределённости решения.

Отдельно была проанализирована зависимость результата от качества данных и выявлено, что наличие разрывов записи или локальных искажений приводит к снижению коэффициента корреляции и нестабильности оценки сдвига. В подобных случаях наблюдается либо существенное снижение максимального значения корреляции, либо неустойчивость положения максимума при изменении длины интервала. Такие случаи являются показателем наличия проблем в данных и требуют привлечения к анализу инженера.

Оптимальным диапазоном длины интервала по результатам тестирования является 20–25 м. При меньших значениях возможно снижение информативности сигнала, а при чрезмерном увеличении длины в анализируемый сегмент могут попадать неоднородные участки или зоны с пропусками данных, что снижает корреляцию. Таким образом, устойчивость алгоритма определяется не только длиной окна, но и структурной однородностью интервала.

Для успешных автоматических случаев средняя абсолютная величина смещения относительно экспертной разметки составила не более 0,5 м, что соответствует требованиям промышленной геонавигации и обеспечивает корректную глубинную привязку повторной записи.

#### **4.2.3. Примеры работы алгоритма**

В случае достаточного качества данных и наличия выраженной структуры гамма-каротажа алгоритм стабильно выделяет один и тот же интервал сходимости независимо от выбранной длины перезаписи.

На рисунках 36–38 приведён пример устойчивой работы алгоритма при последовательном увеличении длины интервала перезаписи с 15 до 45 м. Верхняя кривая на каждом рисунке соответствует исходной записи гамма-каротажа, нижняя – перезаписи. При длине окна 15 м (рисунок 36) коэффициент корреляции составляет 0,95, вычисленный сдвиг равен 1 м. При увеличении длины интервала до 25 м (рисунок 37) корреляция возрастает до 0,96 при сохранении того же значения сдвига. При дальнейшем увеличении окна до 45 м (рисунок 38) коэффициент корреляции достигает 0,97, при этом положение максимума

корреляции остаётся неизменным. Такая инвариантность решения относительно длины окна свидетельствует о корректной привязке перезаписи и рассматривается как критерий устойчивости алгоритма. В практическом применении подобная картина позволяет использовать полученное значение сдвига без дополнительного ручного анализа.




Рисунок 36. Пример устойчивого определения интервала сходимости при длине перезаписи 15 м (коэффициент корреляции 0,95, вычисленный сдвиг 1 м).




Рисунок 37. Работа алгоритма при увеличении длины перезаписи до 25 м: сохранение положения максимума корреляции (коэффициент корреляции 0,96).




Рисунок 38. Работа алгоритма при длине перезаписи 45 м: устойчивость найденного интервала и стабилизация коэффициента корреляции (0,97).

На рисунках 39–41 приведён пример работы алгоритма в условиях пониженного качества записи и наличия пропусков («дыр») в интервале перезаписи. При длине окна 15 м (рисунок 39) коэффициент корреляции составляет 0,34 при вычисленном сдвиге 4 м. Уже на этом этапе наблюдается низкое значение корреляции, не соответствующее критериям устойчивого решения. При увеличении длины окна до 20 м (рисунок 40) коэффициент корреляции снижается до 0,25, а вычисленный сдвиг изменяется до -6 м. При дальнейшем увеличении длины интервала до 30 м (рисунок 41) корреляция остаётся низкой (0,32), а значение сдвига смещается до -10 м. Таким образом, при варьировании длины окна коэффициент корреляции остаётся на низком уровне и вычисленный сдвиг демонстрирует существенные изменения.




Рисунок 39. Пример нестабильного решения при длине перезаписи 15 м: низкий коэффициент корреляции (0,34) и отсутствие устойчивого положения максимума.




Рисунок 40. Изменение найденного сдвига при длине перезаписи 20 м: снижение корреляции до 0,25 и смещение сдвига.




Рисунок 41. Работа алгоритма при длине перезаписи 30 м: сохранение низкой корреляции (0,32) и отсутствие инвариантности решения относительно сдвига.

Наблюдаемое поведение указывает на отсутствие устойчивого экстремума функционала корреляции и, следовательно, о невозможности надёжной автоматической привязки. Важно подчеркнуть, что алгоритм в данном случае не формирует ложностабильного решения. Низкие значения корреляции и вариативность найденного сдвига однозначно сигнализируют о нестабильности результата. Такое поведение рассматривается как принципиальное преимущество метода, поскольку предотвращает неконтролируемые ошибки глубинной привязки и переводит систему в режим поддержки принятия решения инженером.

С математической точки зрения наблюдается отсутствие выраженного глобального максимума корреляционного функционала в допустимом диапазоне сдвигов, что связано с нарушением структурной целостности анализируемого сигнала вследствие пропусков данных.

Проведённое тестирование позволяет сделать следующие выводы:

1. Алгоритм демонстрирует высокую устойчивость при наличии выраженных геологических реперов.
2. Алгоритм корректно реагирует на ухудшение качества данных, снижая степень автоматизации в потенциально рискованных ситуациях.
3. Оптимальный диапазон длины перезаписи (15–25 м) обеспечивает баланс между информативностью и однородностью интервала.
4. Средняя точность определения сдвига ( $\leq 0,5$  м) соответствует требованиям оперативной геонавигации.

Таким образом, разработанный модуль может быть использован в качестве надёжного инструмента автоматического контроля корректности перезаписи гамма-каротажа в составе промышленного программного обеспечения геонавигации.

### **4.3. Результаты апробации модели распознавания границ при бурении горизонтальной секции**

#### **4.3.1. Постановка эксперимента и особенности данных**

Для оценки предложенной модели распознавания границ, реализованной в виде последовательности обработки данных азимутального плотностного каротажа, были использованы промышленные данные 25 скважин из различных регионов Западной и Восточной Сибири. В выборке присутствовали измерения, полученные приборами с различными радиусами действия и уровнем зашумленности, что позволяет оценить устойчивость предложенного подхода к изменению аппаратных и геологических условий. Экспертная разметка включала порядка 750 паттернов «улыбок», соответствующих пересечениям горизонтальным стволом скважины границ пластов. Для валидации результатов использовалась разметка, выполненная экспертами-геонавигаторами.

Разбиение на обучающую, валидационную и тестовую выборки выполнялось на уровне скважин, что позволило исключить утечку информации между выборками и обеспечить корректную оценку обобщающей способности. При формировании выборок учитывалось распределение количества «улыбок» по скважинам. В результате обучающая выборка (12 скважин) содержит 35 % размеченных «улыбок», валидационная выборка (6 скважин) – 20 %, а тестовая выборка (7 скважин) – 45 %. Объем тестовой выборки был увеличен относительно обучающей, чтобы получить более устойчивую оценку качества последовательности обработки данных.

Обучающая и валидационная выборки использовались для настройки параметров моделей, включая обучение автоэнкодера и классификатора, а также подбор гиперпараметров. Тестовая выборка применялась для финальной оценки качества всей последовательности обработки данных, чтобы исключить смещение и получить независимые от обучения результаты.

В процессе апробации модели анализа азимутального плотностного каротажа имитировался режим поступления данных, характерный для реального процесса

бурения горизонтальной секции. В отличие от офлайн-обработки, при которой доступен полный массив данных по всей глубине, в реальных условиях геонавигации информация поступает по мере разбуривания скважины и должна анализироваться в режиме реального времени. С этой целью обработка данных выполнялась итеративно, с поэтапным увеличением доступного интервала каротажа с шагом 20 м по глубине. На каждом шаге прироста запускалась последовательность обработки данных, реализующая предложенную модель анализа имиджей. Азимутальные изображения разбивались на перекрывающиеся участки (окна) с шагом 5 м, что позволило корректно выявлять объекты, которые занимают лишь часть интервала, а также снизить чувствительность последовательности обработки данных к шуму и локальным изменениям контраста. Чтобы не учитывать дублирующиеся детекции, которые могут возникнуть, если одна и та же «улыбка» обнаружена на нескольких изображениях, применялся специализированный алгоритм подавления немаксимумов (Non-Maximum Suppression, NMS), реализованный с учётом специфики задачи. В качестве критерия объединения использовалась близость ограничивающих прямоугольников по глубине и степень их перекрытия, при этом из группы пересекающихся детекций выбирался объект с максимальной вероятностью принадлежности классу «улыбка». Применение такого подхода позволило устранить избыточные повторные детекции одной и той же структуры и повысить стабильность результатов при пошаговом приросте данных.

Таким образом, процедура тестирования в максимальной степени приближена к реальным условиям геонавигации и демонстрирует работоспособность предложенной модели в режиме последовательного поступления данных при бурении.

#### **4.3.2. Обучение и применение автоэнкодера**

Для предварительной фильтрации азимутальных изображений использовалась сверточная модель автоэнкодера. Обучение выполнялось на исходных азимутальных изображениях без использования экспертной разметки.

Входные данные представляли собой изображения размерности  $H \times 16$ , что обусловлено количеством азимутальных каналов прибора. Узкая ширина изображения накладывает ограничения на архитектуру модели и требует сохранения разрешения по азимутальному направлению.

В процессе обучения использовалась комбинированная функция потерь (3.5), описанная в разделе 3.2.4, включающая попиксельную, структурную, градиентную и сглаживающую компоненты. Обучение проводилось в течение 40 эпох с использованием оптимизатора Adam. Качество оценивалось на валидационной выборке, после чего модель с наилучшим качеством использовалась для дальнейшей обработки данных. Процесс обучения автоэнкодера характеризуется устойчивым уменьшением значения суммарной функции потерь на обучающей выборке (рисунок 42). На начальных эпохах наблюдается резкое снижение ошибки, что соответствует этапу грубого восстановления структуры изображений. На последующих эпохах уменьшение функции потерь замедляется, что свидетельствует о переходе к уточнению деталей реконструкции. Значения функции потерь на валидационной выборке изменяются согласованно с обучающей, что говорит об отсутствии выраженного переобучения и подтверждает обобщающую способность модели.

На рисунке 43 показана динамика структурной метрики SSIM, характеризующей степень сохранения пространственной структуры изображений. Значения метрики быстро возрастают на начальных эпохах обучения и достигают уровня порядка 0,9, после чего колеблются в узком диапазоне. Это говорит о том, что автоэнкодер эффективно восстанавливает геометрические особенности изображений, включая протяжённые контрастные границы.




Рисунок 42. Динамика суммарной функции потерь на обучающей и валидационной выборках в процессе обучения автоэнкодера.




Рисунок 43. Изменение структурной метрики SSIM на валидационной выборке в процессе обучения автоэнкодера.

#### 4.3.3. Качество классификатора как отдельного компонента

Классификатор в составе предложенной последовательности обработки данных предназначен для решения задачи бинарной классификации кандидатных областей, выделенных на предыдущих этапах обработки изображений. В отличие от классической постановки задачи, где модель обучается различать объекты и

произвольный фон, в данном случае классификатор обучался на данных, максимально приближённых к условиям его последующего применения.

Формирование обучающей выборки осуществлялось следующим образом. Для каждого изображения обучающей выборки выполнялись предварительные этапы последовательности обработки данных. На основе полученных контуров формировался набор прямоугольных областей, потенциально соответствующих геологическим границам. Далее каждый кандидат сопоставлялся с экспертной разметкой: если интервал имел достаточное пересечение с разметкой, он относился к положительному классу, иначе кандидат считался отрицательным примером. Это позволило формировать отрицательные примеры не из произвольных фрагментов изображения, а из реальных кандидатных объектов, которые алгоритм выделил на предыдущих этапах. Это важно в рассматриваемой задаче, поскольку в финальной последовательности обработки данных классификатор получает на вход именно такие кандидатные области, а не случайные участки изображения. Такой подход к формированию обучающей выборке позволяет повысить устойчивость классификатора к ложноположительным срабатываниям и обеспечивает его более эффективное применение в общей последовательности обработки данных.

Работа сверточного бинарного классификатора оценивалась также отдельно на подготовленных патчах изображений. На рисунке 44 приведен график изменения функции потерь в процессе обучения и можно видеть, что на обучающей выборке значения снижаются с увеличением количества эпох, при этом на валидационной выборке, несмотря на наличие колебаний, поведение функции потерь остаётся согласованным с обучающей выборкой, что говорит об отсутствии выраженного переобучения.




Рисунок 44. Динамика изменения функции потерь в процессе обучения.

Для количественной оценки качества работы алгоритма бинарной классификации обычно используются такие метрики, как точность (precision), полнота (recall) и F1-мера. В задаче обучения классификатора под положительным классом понимаются интервалы, соответствующие геологическим границам типа «улыбка». Сопоставление предсказанных и эталонных интервалов выполнялось на основе пересечения по глубине. Введём следующие обозначения:

- TP (true positive) – количество корректно классифицированных геологических границ;
- FP (false positive) – количество ложноположительных срабатываний, когда алгоритм выделяет объект, не соответствующий экспертной разметке «улыбок»;
- FN (false negative) – количество пропущенных алгоритмом положительных объектов, присутствующих в экспертной разметке.

На основе этих величин рассчитываются следующие метрики:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (4.1)$$

Точность (precision) показывает долю корректно обнаруженных «улыбок» среди всех найденных объектов. Метрика отражает уровень ложных срабатываний: чем выше точность, тем меньше алгоритм выделяет лишних объектов.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (4.2)$$

Полнота (recall) отражает способность алгоритма находить все реальные «улыбки». Высокое значение полноты означает, что алгоритм редко пропускает геологические границы из экспертной разметки.

F1-мера представляет собой гармоническое среднее точности и полноты:

$$F1 = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4.3)$$

Данная метрика используется для комплексной оценки качества, учитывающей как ложные срабатывания, так и пропуски. На рисунке 45 представлена динамика F1-меры в процессе обучения модели классификатора. Значения метрики на обучающей выборке достигают 0,97, а на валидационной – 0,88–0,90, что говорит о хорошей обобщающей способности модели.




Рисунок 45. Динамика изменения F1-меры в процессе обучения.

Важно подчеркнуть различие между оценкой классификатора и оценкой всей последовательности обработки данных: качество классификатора отражает его работу на корректно сформированных кандидатах, а качество последовательности обработки данных включает ошибки всех предыдущих этапов, включая бинаризацию и контурную фильтрацию.

#### 4.3.4. Анализ работы последовательности обработки данных

На рисунках 46–47 приведены примеры последовательной обработки изображений азимутального каротажа в рамках разработанного подхода. Для каждого изображения визуализированы следующие этапы обработки (слева направо):

1. исходное азимутальное изображение;
2. реконструкция изображения автоэнкодером;
3. бинаризация методом Оцу;
4. выделение границ детектором Канни;
5. извлечение контуров;
6. построение ограничивающих прямоугольников кандидатов;
7. финальная классификация паттернов «улыбок» (положительные предсказания выделены зелёным).

В первом примере (рисунок 46) синусоидальный паттерн выражен достаточно отчётливо, однако на исходном изображении присутствуют локальные шумовые включения. После прохождения через автоэнкодер контур «улыбки» становится более гладким и подавляются второстепенные границы, а детектор Канни выделяет преимущественно одну структуру. В результате классификатор корректно идентифицирует один положительный объект.




Рисунок 46. Пример выделения «улыбки» по данным азимутального каротажа.

Во втором примере (рисунок 47) исходные данные обладают более высокой степенью зашумленности. В данных присутствуют несколько потенциально ложных контуров. Без предварительной фильтрации такие данные приводили бы к множественным ложным кандидатам. В итоге классификатор корректно относит контур к отрицательному классу.




Рисунок 47. Пример классификации объекта, не относящегося к классу «улыбки».

Анализируя продемонстрированные примеры, можно сделать вывод, что применение автоэнкодера как фильтра повышает устойчивость выделения границ в условиях шумных и неравномерных по контрасту данных – изображения становятся более однородными по фону, а контрастные переходы, соответствующие геологическим границам, усиливаются. Это упрощает последующие этапы бинаризации, контурной фильтрации и классификации.

Для количественной оценки качества предложенного подхода на тестовой выборке использовались метрики бинарной классификации: точность (4.1), полнота (4.2) и F1-мера (4.3). В рассматриваемой задаче под положительным классом понимаются интервалы, соответствующие геологическим границам. Сопоставление предсказанных и эталонных интервалов выполнялось на основе пересечения по глубине. По результатам оценки на тестовой выборке получены следующие значения:  $TP = 291$ ,  $FP = 155$ ,  $FN = 51$ . Соответствующие метрики составили: точность (precision) – 65 %, полнота (recall) – 85 %, F1-мера – 74 %.

Значение полноты 85 % показывает, что основная часть размеченных геологических границ была успешно обнаружена алгоритмом. Это важно для задач геонавигации, поскольку пропуск границ может привести к снижению эффективности бурения. Большинство пропущенных алгоритмом объектов из экспертной разметки относятся к интервалам с низким качеством записи или браком данных азимутального каротажа. Снижение точности связано с появлением интервалов, ошибочно отнесённых алгоритмом к «улыбкам». Анализ таких случаев показал, что значительная их часть соответствует структурам, визуально схожим с «улыбками», а также может быть связана с неполнотой или неоднозначностью экспертной разметки.

Полученные результаты показывают, что настройка алгоритма ориентирована прежде всего на снижение числа пропущенных объектов, даже если это сопровождается увеличением количества ложных срабатываний. Такой результат оправдан в рассматриваемой задаче, поскольку приоритетом является минимизация пропусков пересечений границ пластов.

#### 4.3.5. Определение угла залегания структуры по выделенным «улыбкам»

После автоматического выделения и классификации паттернов «улыбок» следующим этапом является вычисление угла залегания структуры. Расчёт выполняется последовательно (рисунок 48) и включает:

1. оценку длины «улыбки» по измеренным глубинам;
2. вычисление угла между осью скважины и пересекаемой структурой;
3. определение угла залегания пласта с учётом наклона траектории скважины.




Рисунок 48. Пересечение пропластка прибором, собирающим данные по квадрантам, где:  $L$  – расстояние между точками пересечений в измеренных глубинах;  $D$  – эффективный диаметр ствола;  $\alpha$  – структурный угол пропластка в разрезе скважины (град);  $I$  – угол наклона траектории скважины (град)

Длина «улыбки» определяется как разность измеренных глубин начала ( $MD_1$ ) и конца ( $MD_2$ ) структуры  $L = MD_2 - MD_1$ . Эффективный диаметр ствола

скважины рассчитывается как  $D = d + 2 * DOI$ , где  $d$  – диаметр долота,  $DOI$  – глубина проникновения прибора. Далее вычисляется угол  $\beta$  между осью скважины и структурой:  $\beta = \tan^{-1} \left( \frac{D}{L} \right)$ , а угол залегания структуры определяется по формуле:

$$\alpha = 90^\circ - I - \beta, \quad (4.4)$$

где  $I$  – угол наклона траектории скважины.

Практическая ценность данного расчёта состоит в том, что после автоматического выделения геологических границ алгоритм позволяет получить не только факт наличия структуры, но и количественную характеристику, используемую для обновления геонавигационной модели и принятия решений по корректировке траектории бурения.

#### **4.3.6. Обсуждение результатов и практическая применимость**

Предложенный гибридный подход, основанный на применении методов глубокого обучения и классических алгоритмов компьютерного зрения, демонстрирует высокую эффективность для задачи автоматического выделения геологических границ. Автоэнкодер позволяет повысить устойчивость алгоритма к шумам и артефактам исходных данных, а классификатор обеспечивает выделение целевых объектов на основе статистических закономерностей, извлечённых из обучающей выборки.

Разработанный алгоритм реализован в составе промышленного программного обеспечения и продемонстрировал способность автоматически выявлять геологические структуры на данных с различным качеством записи, при этом сохраняя приемлемые значения точности и полноты.

Важно отметить, что модульная структура последовательности обработки данных обеспечивает её масштабируемость и возможность адаптации к новым данным. В частности, классификатор может быть дообучен при расширении обучающей выборки, что позволит сохранить качество распознавания на новых данных без изменения общей архитектуры алгоритма. Это делает предложенный

метод перспективным для использования в задачах оперативной геонавигации при бурении горизонтальных скважин, где требуется устойчивое обнаружение геологических границ в условиях ограниченного времени и вариативности исходных данных.

#### **Основные выводы к главе 4**

1. Методика уточнения положения кровли целевого пласта в транспортной секции показала работоспособность в условиях, приближенных к реальному процессу бурения. В ходе тестирования имитировался поэтапный прирост данных каротажа и прогноз положения кровли пересчитывался на каждом шаге. Средняя величина отклонения прогнозного положения кровли от фактического составила порядка нескольких метров, что соответствует требованиям геонавигации. Показано, что использование проверки по мощности позволяет автоматически исключать опорные скважины с несоответствующей геологической моделью и тем самым повышать устойчивость прогноза.
2. Алгоритм автоматического анализа перезаписи гамма-каротажа продемонстрировал высокую эффективность при решении задачи поиска сдвига между интервалом основного каротажа и интервалом перезаписи. Алгоритм устойчиво определяет интервал сходимости и величину сдвига по глубине в 86% тестовых случаев для интервалов с выраженными реперами.
3. Модель анализа азимутального плотностного каротажа в горизонтальной секции, основанная на последовательности обработки данных (автоэнкодер, контурная фильтрация, классификация), показала способность автоматически выделять геологические границы типа «улыбок» в условиях шумных данных. Использование автоэнкодера в качестве структурного фильтра повысило устойчивость выделения границ и позволило увеличить количество корректно обнаруженных структур по сравнению с подходом без автоэнкодера. Качество классификатора как отдельного компонента подтвердило его высокую способность различать паттерны «улыбка/фон», а

совокупные показатели последовательности обработки данных отражают сбалансированный компромисс между чувствительностью и точностью, приемлемый для задач геонавигации.

4. Практическая значимость предложенных решений заключается в том, что разработанные методики ориентированы на автоматизацию ключевых этапов геонавигации. Модульный подход обеспечивает устойчивость, интерпретируемость результатов и совместимость с существующими рабочими процессами геонавигаторов. Реализация алгоритмов в составе корпоративного программного обеспечения и их апробация на промышленных данных подтверждают возможность практического внедрения предложенных решений для повышения скорости, воспроизводимости и качества геонавигационных решений.

## ЗАКЛЮЧЕНИЕ

### Основные результаты и выводы:

1. Разработан целостный комплекс моделей для геонавигации, объединяющий прогноз положения кровли целевого интервала в транспортной секции, распознавание геологических структур на азимутальных изображениях в горизонтальной секции, а также контроль сходимости перезаписей гамма-каротажа при переходе от транспортной к горизонтальной секции.
2. Сформулирован и реализован новый модифицированный алгоритм динамической трансформации временной шкалы для сопоставления интервалов каротажа при геонавигации в реальном времени и последующего уточнения расстояния до кровли целевого пласта при бурении транспортной секции горизонтальной скважины, отличающийся тем, что это обеспечивает более устойчивую и физически согласованную привязку интервалов каротажа по сравнению с классической версией алгоритма.
3. Предложена новая математическая модель распознавания геологических границ пласта на азимутальных изображениях в окрестности горизонтального ствола бурящейся скважины с учётом цилиндрической геометрии; реализована обучаемая композиция на основе алгоритмов компьютерного зрения и сверточных нейронных сетей, что обеспечивает устойчивую работу при ограниченной разметке и прямую геологическую интерпретацию.
4. Впервые сформулирован и реализован алгоритм для автоматического поиска сдвига перезаписи гамма-каротажа при переходе от транспортной к горизонтальной секции.
5. Разработанный комплекс моделей и алгоритмов позволяет обеспечить раннее выявление выхода из продуктивного пласта в горизонтальной секции и уточнение положения кровли в транспортной секции для

оперативной корректировки траектории бурящейся скважины в реальном времени.

6. Разработанные решения проверены на реальных данных бурящихся скважин из разных регионов и интегрированы в программное обеспечение геонавигации, где применяются в режиме непрерывного сопровождения бурения горизонтальных скважин.

## СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Калинин А.Г., Левицкий А.З., Никитин Б.А. Технология бурения разведочных скважин на нефть и газ: учебник для вузов. – М.: Недра, 1998. – 440 с.
2. Коршак А.А., Шаммазов А.М. Основы нефтегазового дела: учебник для вузов. – 3-е изд., испр. и доп. – Уфа: ДизайнПолиграфСервис, 2005. – 528 с.
3. Kullawan K., Bratvold R.B., Bickel J.E. A Decision Analytic Approach to Geosteering Operations // SPE Drilling & Completion. – 2014. – Vol. 29, No. 1. – P. 36–46. – DOI: 10.2118/167433-PA.
4. Chen Y., Lorentzen R.J., Vefring E.H. Optimization of Well Trajectory Under Uncertainty for Proactive Geosteering // SPE Journal. – 2015. – Vol. 20. – DOI: 10.2118/172497-PA.
5. Alyaev S., Suter E., Bratvold R. [et al.] A Decision Support System for Multi-target Geosteering // Journal of Petroleum Science and Engineering. – 2019. – Vol. 183. – Article 106381. – DOI: 10.1016/j.petrol.2019.106381.
6. Кульчицкий В.В., Григашкин Г.А., Ларионов А.С., Щебетов А.В. Геонавигация скважин: учебное пособие. – М.: МАКС Пресс, 2008. – 312 с.
7. Стищенко С.И., Сабиров А.Н. Геонавигация в 5 кликов. – М.: ЕАГЕ Геомодель, 2018. – 160 с.
8. Doveton J.H. Log Analysis of Subsurface Geology: Concepts and Computer Methods. – Tulsa: AAPG, 1986.
9. Rider M.H., Kennedy M. The Geological Interpretation of Well Logs. – 3rd ed. – Rogart: Rider-French Consulting Ltd., 2011.
10. Chen M.Y., Dahan C., Ekstrom M.P. [et al.] Formation Imaging with Microelectrical Scanning Arrays // The Log Analyst. – 1987. – Vol. 28.
11. Serra O. Formation MicroScanner Image Interpretation. – Houston: Schlumberger Educational Services, 1989.
12. Davies D.H. [et al.] Azimuthal Resistivity Imaging: A New-Generation Laterolog // SPE Formation Evaluation. – 1994. – Vol. 9, No. 3. – P. 165–174. – DOI: 10.2118/23501-PA.

13. Peshkov G., Pavlov M., Katterbauer K., Al Shehri A. Real-Time AI Geosteering for Horizontal Well Trajectory Optimization // SPE Caspian Technical Conference and Exhibition. – Baku, Azerbaijan, 21–23 November 2023. – Paper SPE-217527-MS. – DOI: 10.2118/217527-MS.
14. Muhammad R.B., Srivastava A., Alyaev S. [et al.] High-Precision Geosteering via Reinforcement Learning and Particle Filters // Computational Geosciences. – 2025. – Vol. 29. – DOI: 10.1007/s10596-025-10352-y.
15. Кульчицкий В. В. Геонавигация горизонтальных скважин // Нефтяное хозяйство. – 2020. – № 12. – С. 91–95.
16. Сребродольская М. А., Мисетов Г. А. Современные тенденции в геонавигации горизонтальных скважин по данным каротажа в процессе бурения // Neftegaz.RU. – 2025. – № 12.
17. Габитов С. И. [и др.] Сопровождение бурения высокотехнологичных скважин на основе интеграции методов геомеханики и геонавигации // Нефтегазовое дело. – 2020. – Т. 18, № 2. – С. 15–23. – DOI: 10.17122/ngdelo-2020-2-15-23.
18. Торопецкий К. В. [и др.] Технология сопровождения строительства скважин // Автоматизация, телемеханизация и связь в нефтяной промышленности. – 2017. – № 12. – С. 4–15.
19. Denisenko I.V., Kuvaev I.A., Uvarov I.B. [et al.] Automated Geosteering While Drilling Using Machine Learning. Case Studies // SPE Russian Petroleum Technology Conference. – Virtual, 26–29 October 2020. – Paper SPE-202046-MS. – DOI: 10.2118/202046-MS.
20. Timonov A.V., Khabibullin R.A., Gurbatov N.S. [et al.] Automated Geosteering Optimization Using Machine Learning // Abu Dhabi International Petroleum Exhibition & Conference. – Abu Dhabi, UAE, November 2021. – Paper SPE-207364-MS. – DOI: 10.2118/207364-MS.
21. Черников А. Д. [и др.] Применение методов искусственного интеллекта для выявления и прогнозирования осложнений при строительстве нефтяных и газовых скважин: проблемы и основные направления решения // Георесурсы. – 2020. – Т. 22, № 3. – С. 87–96. – DOI: 10.18599/grs.2020.3.87-96.

22. Еремин Н. А. [и др.] Цифровые технологии строительства скважин. Создание высокопроизводительной автоматизированной системы предотвращения осложнений и аварийных ситуаций в процессе строительства нефтяных и газовых скважин // *Neftegaz.RU*. – 2020. – № 4(100). – С. 38–50.
23. Koroteev D., Tekic Z. Artificial intelligence in oil and gas upstream: Trends, challenges, and scenarios for the future // *Energy and AI*. – 2021. – Vol. 3. – Article 100041. – DOI: 10.1016/j.egyai.2020.100041.
24. Gurina E., Antipova K., Klyuchnikov N. [et al.] Drilling with AI-Based Systems: To Trust, or Not to Trust Model Forecast with Low Quality Real-Time Data? // *GOTECH 2025*. – Dubai City, UAE, 21–23 April 2025. – Paper SPE-224548-MS. – DOI: 10.2118/224548-MS.
25. Shahriari M., Pardo D., Picón A. [et al.] A Deep Learning Approach to the Inversion of Borehole Resistivity Measurements // *Computational Geosciences*. – 2020. – Vol. 24, no. 3. – P. 971–994. – DOI: 10.1007/s10596-019-09917-1.
26. Fossum K., Alyaev S., Tveranger J., Elsheikh A. Deep Learning for Prediction of Complex Geology Ahead of Drilling // *Computational Science – ICCS 2021: 21st International Conference, Krakow, Poland, June 16–18, 2021, Proceedings, Part II*. – Berlin; Heidelberg: Springer-Verlag, 2021. – P. 466–479. – DOI: 10.1007/978-3-030-77964-1\_36.
27. Cayeux E. Autonomous Decision-Making While Drilling // *Energies*. – 2021. – Vol. 14. – Art. 969. – DOI: 10.3390/en14040969.
28. Maus S. [et al.] Automated Geosteering with Fault Detection and Multi-Solution Tracking // *IADC/SPE International Drilling Conference and Exhibition*. – 2020. – DOI: 10.2118/199660-MS.
29. Heintzelman L. [et al.] Field Validation of an Automated Geosteering Algorithm in the Haynesville Shale // *IADC/SPE International Drilling Conference and Exhibition*. – Galveston, USA, 2022. – DOI: 10.2118/208697-MS.
30. Bartosik S. C., Amirlatifi A. Machine Learning Assisted Geosteering // *54th US Rock Mechanics/Geomechanics Symposium*. – 2020.

31. Zhu D. Deep Learning Approach of Drilling Decision for Subhorizontal Drain Geosteering Based on APC-LSTM Model // SPE Drilling & Completion. – 2022. – DOI: 10.2118/210605-PA.
32. Romanenkova E. [et al.] Real-Time Data-Driven Detection of the Rock-Type Alteration During a Directional Drilling // IEEE Geoscience and Remote Sensing Letters. – 2020. – Vol. 17, no. 11. – P. 1861–1865. – DOI: 10.1109/LGRS.2019.2959845.
33. Даниловский К. Н. [и др.] Программное обеспечение на основе веб-технологий для геонавигации нефтегазовых скважин // Вестник НГУ. Серия: Информационные технологии. – 2019. – Т. 17, № 2. – С. 5–17. – DOI: 10.25205/1818-7900-2019-17-2-5-17.
34. Галкина А. В., Каневская Р. Д. О современных подходах к решению задачи автоматической корреляции геологических разрезов скважин // Автоматизация и информатизация ТЭК. – 2025. – № 3(620). – С. 56–64.
35. Rudman A.J., Lankston R.W. Stratigraphic Correlation of Well Logs by Computer Techniques // AAPG Bulletin. – 1973. – Vol. 57, No. 3. – P. 577–588. – DOI: 10.1306/819A4306-16C5-11D7-8645000102C1865D.
36. Mann C.J., Dowell T.P.L. Quantitative Lithostratigraphic Correlation of Subsurface Sequences // Computers & Geosciences. – 1978. – Vol. 4, No. 3. – P. 295–306. – DOI: 10.1016/0098-3004(78)90064-X.
37. Startzman R.A., Kuo T., [et al.] A Rule-Based System for Well Log Correlation // SPE Formation Evaluation. – 1987. – Vol. 2, No. 3. – P. 311–319. – DOI: 10.2118/15295-PA.
38. Lineman D.J., Mendelson J.D., Toksoz M.N. Well-to-Well Log Correlation Using Knowledge-Based Systems and Dynamic Depth Warping. – Cambridge: Massachusetts Institute of Technology, 1987.
39. Olea R.A. Expert Systems for Automated Correlation and Interpretation of Wireline Logs // Mathematical Geology. – 1994. – Vol. 26, No. 8. – P. 879–897. – DOI: 10.1007/BF02083420.

40. Гутман И.С., Балабан И.Ю., Кузнецова Г.П. [и др.] Отечественный комплекс AutoCorr для выполнения корреляции разрезов скважин // Вестник ЦКР Роснедра. – 2005. – № 2. – С. 51–62.
41. Ковалевский Е.В., Гогоненков Г.Н., Перепечкин М.В. Уточнение геологических моделей посредством использования автоматической корреляции скважин // Недропользование XXI век. – 2007. – № 4. – С. 28–31.
42. Sakoe H., Chiba S. Dynamic Programming Algorithm Optimization for Spoken Word Recognition // IEEE Transactions on Acoustics, Speech and Signal Processing. – 1978. – Vol. 26, No. 1. – P. 43–49. – DOI: 10.1109/TASSP.1978.1163055.
43. Le Nir I., Van Gysel N., Rossi D. Cross-Section Construction from Automated Well Log Correlation: A Dynamic Programming Approach Using Multiple Well Logs // SPWLA 39th Annual Logging Symposium. – Keystone, USA, 1998.
44. Yan H., Yan H., Xiang Z., Wang Y. An Improved Dynamic Programming Method for Automatic Stratigraphic Correlation // Journal of Earth Science. – 2003. – Vol. 14, No. 3. – P. 242–244.
45. Zoraster S., Paruchuri R., Darby S. Curve Alignment for Well-to-Well Log Correlation // SPE Annual Technical Conference and Exhibition. – Houston, USA, 2004. – DOI: 10.2118/90471-MS.
46. Grant C.W., Bashore W.M., Compton S. Rapid Reservoir Modeling with Automated Tops Correlation // Unconventional Resources Technology Conference. – Houston, USA, 2018. – DOI: 10.15530/URTEC-2018-2904037.
47. Mirowski P., Herron M., Seleznev N., Fluckiger S., McCormick D. New Software for Well-to-Well Correlation of Spectroscopy Logs [Электронный ресурс]. – URL: [https://www.searchanddiscovery.com/documents/abstracts/2005intl\\_paris/mirowski.htm](https://www.searchanddiscovery.com/documents/abstracts/2005intl_paris/mirowski.htm)
48. Бурлаков Н.С. Математическое, алгоритмическое и программное обеспечение для идентификации структурных объектов: дис. ... канд. техн. наук. – М., 2014. – 243 с.
49. Behdad A. A step toward the practical stratigraphic automatic correlation of well logs using continuous wavelet transform and dynamic time warping technique // Journal of Applied Geophysics. – 2019. – DOI: 10.1016/j.jappgeo.2019.05.007.

50. Латыпов И.Д., Марков А.В., Евграфов Н.А., Шагимарданова Л.Р. Автоматизированная внутрипластовая корреляция по данным ГИС с применением машинного обучения // Экспозиция Нефть Газ. – 2024. – № 4. – С. 47–51. – DOI: 10.24412/2076-6785-2024-4-47-51.
51. Тунев И. С., Барях В. А. Автоматизация межскважинной корреляции с использованием алгоритма динамической трансформации временной шкалы: опыт применения // Недропользование. – 2025. – Т. 25, № 2. – С. 66–74. – DOI: 10.15593/2712-8008/2025.2.2.
52. Wheeler L., Hale D. Simultaneous Correlation of Multiple Well Logs // SEG Technical Program Expanded Abstracts. – 2014. – P. 618–622. – DOI: 10.1190/SEGAM2014-0227.1.
53. Sylvester Z. Automated Multi-Well Stratigraphic Correlation and Model Building Using Relative Geologic Time // Basin Research. – 2023. – Vol. 35, No. 5. – DOI: 10.1111/bre.12787.
54. Wu X., Shi Y., Fomel S., Li F. Incremental Correlation of Multiple Well Logs Following Geologically Optimal Neighbors // SEG International Exposition and Annual Meeting. – 2017. – P. 1945–1949. – DOI: 10.1190/SEGAM2017-17779046.1.
55. Keogh E.J., Pazzani M.J. Derivative Dynamic Time Warping // Proceedings of the SIAM International Conference on Data Mining. – 2001. – DOI: 10.1137/1.9781611972719.1.
56. Luthi S.M., Bryant I.D. Well-Log Correlation Using a Backpropagation Neural Network // Mathematical Geology. – 1997. – Vol. 29, No. 3. – P. 413–425. – DOI: 10.1007/BF02769643.
57. Le T., Liang L., Zimmermann T., Zeroug S., Heliot D. A Machine-Learning Framework for Automating Well-Log Depth Matching // Petrophysics. – 2019. – Vol. 60, No. 5. – P. 585–595. – DOI: 10.30632/PJV60N5-2019A3.
58. Шарафутдинов Т.Р., Шайбаков Р.А. Апробация алгоритма автокорреляции данных ГИС // Научно-технический вестник НК «Роснефть». – 2012. – № 1. – С. 18–22.

59. Шайбаков Р.А. Разработка метода детальной автокорреляции разрезов скважин // Нефтегазовое дело. – 2013. – № 5. – С. 131–151.
60. Maniar H., Ryali S., Kulkarni M.S., Abubakar A. Machine-Learning Methods in Geoscience // SEG International Exposition and Annual Meeting. – 2018. – P. 4638–4642. – DOI: 10.1190/SEGAM2018-2997218.1.
61. Tokpanov Y., Smith J., Ma Z. [et al.] Deep-Learning-Based Automated Stratigraphic Correlation // SPE Annual Technical Conference and Exhibition. – Virtual, 26–29 October 2020. – Paper SPE-201459-MS. – DOI: 10.2118/201459-MS.
62. Dai Y., Huang X., Liu H., Yang H., Wei G., Lu N., Han Z., Song H. Stratigraphic Automatic Correlation Using SegNet Semantic Segmentation Model // SEG/AAPG/SEPM International Meeting for Applied Geoscience & Energy. – 2021. – DOI: 10.1190/SEGAM2021-3584720.1.
63. Yang Y., Wang J., Li Z. [et al.] Automated Stratigraphic Correlation of Well Logs Using Attention-Based Dense Network // Artificial Intelligence in Geosciences. – 2023. – Vol. 4. – P. 128–136. – DOI: 10.1016/j.aiig.2023.09.001.
64. Torres Caceres V.A., Duffaut K., Yazidi A., Westad F., Johansen Y.B. Automated Well Log Depth Matching: Late Fusion Multimodal Deep Learning // Geophysical Prospecting. – 2024. – Vol. 72. – P. 155–182. – DOI: 10.1111/1365-2478.13200.
65. Fan M., Fan X., Chen S. [et al.] Automatic Well-Log Depth Shift with Multilevel Wavelet Decomposition Network and Dynamic Time Warping // Geoenergy Science and Engineering. – 2024. – Vol. 246. – Art. 213583. – DOI: 10.1016/j.geoen.2024.213583.
66. Wang C.Z., Wei X.Y., Pan H. [et al.] Well Logging Stratigraphic Correlation Based on Semantic Segmentation // Applied Geophysics. – 2024. – Vol. 21, No. 4. – P. 650–666. – DOI: 10.1007/s11770-024-1085-8.
67. Salvador S., Chan P. FastDTW: Toward Accurate Dynamic Time Warping in Linear Time and Space // Intelligent Data Analysis. – 2007. – Vol. 11, No. 5. – P. 561–580.
68. Zhao J., Laurent I. ShapeDTW: Shape Dynamic Time Warping [Электронный ресурс]. – 2016. – URL: <https://arxiv.org/abs/1606.01601>.
69. Rosa M., Fugmann E., Pinto G., Nunes M. An Anchored Dynamic Time Warping for Alignment of Biomedical Signals // IEEE EMBC Conference. – 2017. – P. 2749–2752.

70. Chang C.Y., Huang D.A., Sui Y., Fei L., Niebles J.C. D3TW: Discriminative Differentiable Dynamic Time Warping // *Proceedings of CVPR*. – 2019. – P. 3541–3550.
71. Jiang Y., Qi Y., Wang W. [et al.] EventDTW: Improved Dynamic Time Warping for Biomedical Signals // *Sensors*. – 2020. – Vol. 20, No. 9. – DOI: 10.3390/s20092700.
72. Rabiner L.R. A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition // *Proceedings of the IEEE*. – 1989. – Vol. 77. – P. 257–286. – DOI: 10.1109/5.18626.
73. Lafferty J., McCallum A., Pereira F. Conditional Random Fields: Probabilistic Models for Segmenting and Labeling Sequence Data // *Proceedings of the International Conference on Machine Learning*. – 2001.
74. Boykov Y., Kolmogorov V. An Experimental Comparison of Min-Cut/Max-Flow Algorithms for Energy Minimization in Vision // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 2004. – Vol. 26, No. 9. – P. 1124–1137. – DOI: 10.1109/TPAMI.2004.60.
75. Kolmogorov V., Zabih R. What Energy Functions Can Be Minimized via Graph Cuts? // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 2004. – Vol. 26, No. 2.
76. Казанцев Г. В. Результаты комплексного анализа азимутальных данных имиджера плотности и сейсмических данных при геонавигации скважин // *Известия высших учебных заведений. Геология и разведка*. – 2025. – Т. 67, № 3. – С. 128–139. – DOI: 10.32454/0016-7762-2025-67-3-128-139.
77. Bondár I. Seismic Horizon Detection Using Image Processing Algorithms // *Geophysical Prospecting*. – 1992. – Vol. 40, No. 7. – P. 785–800. – DOI: 10.1111/j.1365-2478.1992.tb00552.x.
78. Ashraf H., Mousa W.A., Al-Dossary S. Edge-Preserving Smoothing for 3D Seismic Data // *Geophysical Prospecting*. – 2017. – Vol. 65, No. 3. – P. 696–710. – DOI: 10.1111/1365-2478.12447.
79. Canny J. A Computational Approach to Edge Detection // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 1986. – Vol. 8, No. 6. – P. 679–698. – DOI: 10.1109/TPAMI.1986.4767851.

80. Gonzalez R.C., Woods R.E. Digital Image Processing. – 4th ed. – Pearson, 2018.
81. Hough P.V.C. Method and Means for Recognizing Complex Patterns. – U.S. Patent No. 3069654, 1962.
82. Cooper G.R.J. Geophysical Applications of the Hough Transform // South African Journal of Geology. – 2006. – Vol. 109, No. 4. – P. 555–560. – DOI: 10.2113/gssajg.109.4.555.
83. Zhang C.E., Pan B.Z. Feature Recognition Based on Borehole Image Processing // International Conference on Information Science and Engineering. – 2010. – DOI: 10.1109/ICISE.2010.5690580.
84. Fischler M.A., Bolles R.C. Random Sample Consensus: A Paradigm for Model Fitting // Communications of the ACM. – 1981. – Vol. 24, No. 6. – P. 381–395. – DOI: 10.1145/358669.358692.
85. Takagi T., Saitoh F. Curve Detection Using Delaunay Triangulation // Electronics and Communications in Japan. – 2012. – Vol. 95, No. 7. – P. 19–28. – DOI: 10.1002/ecj.11388.
86. Kass M., Witkin A., Terzopoulos D. Snakes: Active Contour Models // International Journal of Computer Vision. – 1988. – Vol. 1. – P. 321–331. – DOI: 10.1007/BF00133570.
87. Chu Y.S. Automatic Dip Picking from Wellbore Image Logs. – Patent WO2015053876A1, 2015.
88. Szeliski R. Computer Vision: Algorithms and Applications. – 2nd ed. – Springer, 2022.
89. Shen J., Liu L., Li S. [et al.] Azimuthal Imaging of Rock Fractures Using Borehole Data [Электронный ресурс]. – 2024. – URL: <https://arxiv.org/abs/2410.11350>.
90. Duda R.O., Hart P.E., Stork D.G. Pattern Classification. – 2nd ed. – Wiley, 2001.
91. Bishop C.M. Pattern Recognition and Machine Learning. – Springer, 2006.
92. LeCun Y., Bottou L., Bengio Y., Haffner P. Gradient-Based Learning Applied to Document Recognition // Proceedings of the IEEE. – 1998. – Vol. 86, No. 11. – P. 2278–2324.

93. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet Classification with Deep Convolutional Neural Networks // Advances in Neural Information Processing Systems. – 2012.
94. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. – 2016. – DOI: 10.1109/CVPR.2016.90.
95. Zhang P.Y., Sun J.M., Jiang Y.J., Gao J.S. Deep Learning Method for Lithology Identification from Borehole Images // EAGE Conference & Exhibition. – 2017. – DOI: 10.3997/2214-4609.201700945.
96. Cruz R.A.Q., Cacau D.C., dos Santos R.M. [et al.] Automatic Fracture Detection in Borehole Images Using Deep Learning // SIBGRAPI Conference. – 2017. – P. 345–350. – DOI: 10.1109/SIBGRAPI.2017.52.
97. Long J., Shelhamer E., Darrell T. Fully Convolutional Networks for Semantic Segmentation // Proceedings of CVPR. – 2015.
98. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // MICCAI. – 2015.
99. Chen L.C., Papandreou G., Kokkinos I., Murphy K., Yuille A.L. DeepLab: Semantic Image Segmentation with Deep Convolutional Networks // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2017.
100. Koryagin A., Mylzenova D., Khudorozhkov R., Tsimfer S. Seismic Horizon Detection with Neural Networks [Электронный ресурс]. – 2020. – URL: <https://arxiv.org/abs/2001.03390>
101. Азбуханов А. Ф., Бадамшин Б. И., Волков М. Г., Власов С. В. Автоматическая корреляция отражающих горизонтов с использованием нейронных сетей // Нефтяное хозяйство. – 2023. – № 3. – С. 18–21. – DOI: 10.24887/0028-2448-2023-3-18-21.
102. Zhang W., Wu T., Li Z. [et al.] Automatic Detection of Fractures in Well Logging Images // Journal of Sensors. – 2021. – DOI: 10.1155/2021/5577084.

103. Azizzadeh Mehmandost Olya B., Mohebian R., Bagheri H. [et al.] Real-Time Fracture Detection on Image Logs Using Deep Learning // Interpretation. – 2024. – Vol. 12, No. 2. – DOI: 10.1190/INT-2022-0104.1.
104. Vaswani A., Shazeer N., Parmar N. [et al.] Attention Is All You Need // Advances in Neural Information Processing Systems. – 2017.
105. Dosovitskiy A., Beyer L., Kolesnikov A. [et al.] An Image Is Worth 16×16 Words: Transformers for Image Recognition at Scale [Электронный ресурс]. – 2020. – URL: <https://arxiv.org/abs/2010.11929>.
106. Nasim M.Q., Maiti T., Mosavat N. [et al.] Automated Detection of Geological Features Using Deep Learning // SPE Journal. – 2025. – DOI: 10.2118/223976-PA.
107. Yu S., Ma J., Osher S. [et al.] Deep Learning for Geophysics: Current and Future Trends // Reviews of Geophysics. – 2021. – DOI: 10.1029/2021RG000742.
108. Monteiro B.A., Canguçu G.L., Jorge L.M.S. [et al.] Deep Learning for Seismic Image Segmentation: Review // Earth-Science Reviews. – 2024. – DOI: 10.1016/j.earscirev.2024.104955.
109. An Y., Zhang J., Li X. [et al.] Deep Learning for Seismic Fault Interpretation: Review // Earth-Science Reviews. – 2023.
110. Vincent P., Larochelle H., Bengio Y., Manzagol P.A. Extracting and Composing Robust Features with Denoising Autoencoders // Proceedings of ICML. – 2008.
111. Saad O.M., Chen Y. Deep Denoising Autoencoder for Seismic Noise Attenuation // Geophysics. – 2020. – Vol. 85, No. 4.
112. Zhang K., Zuo W., Chen Y., Meng D., Zhang L. Beyond a Gaussian Denoiser: Residual Learning for Image Denoising // IEEE Transactions on Image Processing. – 2017. – Vol. 26, No. 7.
113. Van Rijsbergen C.J. Information Retrieval. – London: Butterworth-Heinemann, 1979.
114. Everingham M., Van Gool L., Williams C.K.I., Winn J., Zisserman A. The Pascal Visual Object Classes Challenge // International Journal of Computer Vision. – 2015.

115. Minaee S., Tajbakhsh N., Pham T.Q. [et al.] Image Segmentation Using Deep Learning: Survey // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2021.
116. Wang Z., Bovik A.C., Sheikh H.R., Simoncelli E.P. Image Quality Assessment: Structural Similarity // IEEE Transactions on Image Processing. – 2004.
117. Zhang Z., Li Y., Song M. Road Extraction by Deep Residual U-Net // IEEE Geoscience and Remote Sensing Letters. – 2018.
118. Kingma D.P., Ba J. Adam: A Method for Stochastic Optimization // Proceedings of ICLR. – 2015.
119. Loshchilov I., Hutter F. Decoupled Weight Decay Regularization // Proceedings of ICLR. – 2019.
120. Bottou L., Curtis F.E., Nocedal J. Optimization Methods for Large-Scale Machine Learning // SIAM Review. – 2018.
121. Nocedal J., Wright S. Numerical Optimization. – Springer, 1999.
122. Галкина А. В., Лисицына М. Ю., Рахимов Т. Р., Филатов Д. А., Филимонов В. П. Разработка алгоритма и программного модуля для автоматического анализа сходимости и качества данных гамма-каротажа при геонавигации // Нефтяное хозяйство. – 2020. – № 11. – С. 48–50.
123. Галкина А. В., Каневская Р. Д. Математическое моделирование горизонтальной секции бурящейся скважины по данным азимутального плотностного каротажа // Автоматизация и информатизация ТЭК. – 2025. – № 9(626). – С. 27–35.
124. Sobel I., Feldman G. A 3×3 Isotropic Gradient Operator for Image Processing. – Stanford AI Lab, 1968.
125. Otsu N. Threshold Selection Method from Gray-Level Histograms // IEEE Transactions on Systems, Man, and Cybernetics. – 1979.
126. Suzuki S., Abe K. Topological Structural Analysis of Binary Images // Computer Vision, Graphics, and Image Processing. – 1985.

## ПРИЛОЖЕНИЕ А. ТЕРМИНЫ И ОПРЕДЕЛЕНИЯ

**Азимутальное каротажное изображение** – развёрнутое на плоскость представление данных, полученных прибором, измеряющим физические свойства пород по окружности ствола скважины в процессе бурения или после его завершения.

**Геонавигация** – процесс управления траекторией скважины в режиме реального времени на основе интерпретации геолого-геофизических данных и сопоставления их с геологической моделью.

**Горизонтальная скважина (ствол)** – скважина (или её участок), пробуренная в заданном азимутальном направлении преимущественно вдоль напластования целевого пласта в пределах его вертикальных границ (кровля–подошва, флюидоразделяющие контакты либо их сочетание).

**Интервал перезаписи** – участок повторной записи каротажных данных, используемый для уточнения глубинной привязки и контроля корректности интерпретации.

**Контурная фильтрация** – этап обработки изображения, направленный на выделение потенциальных границ и структурных элементов без их предварительной семантической интерпретации.

**Опорная скважина** – скважина или её интервал (пилотный ствол, наклонно-направленный участок либо фрагмент горизонтального ствола), для которых известны геолого-геофизические данные целевого интервала и которые используются в качестве эталона при корреляции и прогнозировании положения пластов.

**Реперный горизонт (репер, граница, маркер)** – характерный пласт или выраженное изменение физических свойств пород, фиксируемое на каротажных диаграммах, электрических и сейсмических разрезах, позволяющее сопоставлять геологические разрезы и прослеживать границы пластов.

**Транспортный ствол** – наклонно-направленная секция скважины, предназначенная для набора угла с целью обеспечения оптимального размещения горизонтального участка внутри целевого пласта.

**Целевой пласт (интервал)** – интервал пласта, выбранный для размещения горизонтальной скважины или бокового горизонтального ствола с целью обеспечения максимальной эффективности разработки и извлечения углеводородов.

**«Улыбка»** – синусоидальный паттерн на азимутальном каротажном изображении, возникающий при пересечении геологической границы цилиндрической поверхностью ствола скважины и используемый для оценки угла залегания структуры.

## **ПРИЛОЖЕНИЕ Б. ПЕРЕЧЕНЬ УСЛОВНЫХ ОБОЗНАЧЕНИЙ И СОКРАЩЕНИЙ**

АО – абсолютная отметка глубины

ГИС – геофизические исследования скважин

ML – Machine Learning, машинное обучение

DL – Deep Learning, глубокое обучение

CV – Computer Vision, компьютерное зрение

CNN – Convolutional Neural Network, сверточная нейронная сеть

AE – Autoencoder, автоэнкодер

DTW – Dynamic Time Warping, динамическая трансформация временной шкалы

SDTW – Subsequence Dynamic Time Warping, динамическая трансформация временной шкалы для подпоследовательностей