

Министерство науки и высшего образования Российской Федерации
Санкт-Петербургский политехнический университет Петра Великого
Физико-механический институт
Высшая школа теоретической механики и математической физики

Работа допущена к защите

Директор ВШТМиМФ,

Д.ф.-м.н., чл.-корр. РАН

_____ А.М. Кривцов

« ___ » _____ 2024 г.

ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА

магистерская диссертация

НЕЙРОСЕТЕВЫЕ МЕТОДЫ ПОСТРОЕНИЯ КУБОВ ГЕОФИЗИЧЕСКИХ АТТРИБУТОВ

по направлению подготовки

01.04.03 Механика и математическое моделирование

Направленность (профиль)

01.04.03_04 Математическое моделирование процессов нефтегазодобычи

Выполнил

студент гр. 5040103/20401

А.А. Алтаева

Руководитель

доцент ВШТМиМФ, к.ф.-м.н.

А.А. Ле-Захаров

Консультанты

Профессор ВШТМиМФ, д.т.н.

М.М. Хасанов

Рук. напр. ООО Инженерно-

технологический сервис

Ф.И. Кондратенко

Санкт-Петербург – 2024 г

**САНКТ-ПЕТЕРБУРГСКИЙ ПОЛИТЕХНИЧЕСКИЙ
УНИВЕРСИТЕТ ПЕТРА ВЕЛИКОГО**

Физико-механический институт

Высшая школа теоретической механики и математической физики

УТВЕРЖДАЮ

Директор ВШТМиМФ

А. М. Кривцов

«__» _____ 20__ г.

ЗАДАНИЕ

на выполнение выпускной квалификационной работы

студенту Алтаевой Аружан Асылбековне, гр. 5040103/20401

1. Тема работы: Нейросетевые методы построения кубов геофизических атрибутов.
2. Срок сдачи студентом законченной работы: 30.05.2024
3. Исходные данные по работе: данные ГИС, актуальные научные публикации по теме работы.
4. Содержание работы (перечень подлежащих разработке вопросов): ряд Фурье, спектральный метод, интерполяция коэффициентов ряда Фурье по пространству, нейронные сети, полносвязная нейронная сеть, интерполяция коэффициентов нейронной сети по пространству, анализ временных рядов.
5. Перечень графического материала (с указанием обязательных чертежей): не предусмотрено
6. Консультанты по работе: М. М. Хасанов, профессор ВШТМиМФ, д.т.н., Ф. И. Кондратенко, руководитель направления ООО Инженерно-технологический сервис
7. Дата выдачи задания 26.02.2024

Руководитель ВКР _____ А.А. Ле-Захаров, доцент ВШТМиМФ, к.ф.-м.н.

Задание принял к исполнению 26.02.2024

Студент _____ А.А. Алтаева

РЕФЕРАТ

На 48 с., 25 рисунков, 8 таблиц, 0 приложений

КЛЮЧЕВЫЕ СЛОВА: ГЕОФИЗИКА, КАРОТАЖ, ПРЕОБРАЗОВАНИЕ ФУРЬЕ, ПРОСТРАНСТВЕННАЯ ИНТЕРПОЛЯЦИЯ, НЕЙРОННЫЕ СЕТИ.

Тема выпускной квалификационной работы: «Нейросетевые методы построения кубов геофизических атрибутов».

Данная работа посвящена разработке нейросетевой модели для прогнозирования данных кубов геофизических атрибутов. В ходе работы была изучена литература, предполагаемой к использованию в данной теме, рассмотрена реализация существующего подхода построения кубов геофизических атрибутов, разработан на языке программирования Python метод построения кубов гамма – каротажа прогнозированием нейронной сетью с дальнейшей пространственной интерполяцией полученных весовых коэффициентов.

ABSTRACT

48 pages, 25 pictures, 8 tables, 0 appendixes

KEYWORDS: GEOPHYSICS, LOGGING, FOURIER TRANSFORM, SPATIAL INTERPOLATION, NEURAL NETWORKS.

The subject of the graduate qualification work is «Neural network methods for building cubes of geophysical attributes».

This work is devoted to the development of a neural network model for predicting geophysical attribute cubes data. In the course of the work was studied the literature intended for use in this topic, considered the implementation of the existing approach of building cubes of geophysical attributes, developed in the programming language Python method of building cubes of gamma - logging prediction by neural network with further spatial interpolation of the obtained weight coefficients.

СОДЕРЖАНИЕ

Введение	5
ГЛАВА 1. ТЕОРЕТИЧЕСКИЕ ОСНОВЫ ГЕОФИЗИЧЕСКИХ ИССЛЕДОВАНИЙ.....	7
1.1. Роль геофизических методов в исследовании земной коры	7
1.2. Виды геофизических атрибутов и их значения в нефтегазовой отрасли	11
1.2.1. Значение геофизических атрибутов в нефтегазовой отрасли ...	13
1.2.2. Каротажные методы	13
ГЛАВА 2. МЕТОД ИНТЕРПОЛЯЦИИ ГАММА – КАРОТАЖА РЯДОМ ФУРЬЕ.....	18
2.1. Постановка задачи	18
2.2. Спектральный метод	18
2.2.1. Дискретное преобразование Фурье	20
2.3. Интерполяция гамма-каротажа рядом Фурье	22
2.4. Интерполяция коэффициентов Фурье по пространству.....	25
ГЛАВА 3. ПОСТРОЕНИЕ КУБОВ ГЕОФИЗИЧЕСКИХ АТТРИБУТОВ С ИСПОЛЬЗОВАНИЕМ НЕЙРОСЕТЕВЫХ МЕТОДОВ	30
3.1. Использование нейросетей для предсказания и интерпретации геофизических атрибутов.....	30
3.2. Виды нейронных сетей.....	31
3.2.1. Архитектура нейронных сетей	33
3.3. Постановка задачи	35
3.4. Предсказание коэффициентов геофизического атрибута при помощи полносвязной нейронной сети.....	36
3.5. Интерполирование коэффициентов нейронной сети по пространству.....	40
Сравнение результатов.....	44
ЗАКЛЮЧЕНИЕ	46
СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ.....	47

ВВЕДЕНИЕ

Современная геофизика активно использует данные, полученные различными методами сейсморазведки, магнитометрии, гравиметрии и других геофизических исследований. Такие данные позволяют строить модели строения недр Земли, которые играют одну из важных ролей в поиске и разработке некоторых полезных ископаемых (например, нефти и газа). Однако эти данные имеют большую размерность и статистическую неопределённость, что затрудняет их корректную интерпретацию в процессе обработки.

Одной из ключевых проблем геофизики является построение кубов геофизических атрибутов — трехмерных массивов данных, описывающих различные физические свойства горных пород. Такие кубы являются основой анализа геологических структур и принятия решений в области разработки полезных ископаемых. На самом деле, традиционные методы построения этих кубов, основанные на прямой интерпретации данных, зачастую отнимают много вычислительных ресурсов и времени. В данной работе рассматриваются нейросетевые методы, которые благодаря возможности обучения сложным закономерностям и работе с большими объемами данных открывают новые возможности повышения эффективности и точности построения кубов геофизических атрибутов.

Геофизические исследования скважин (ГИС) — это комплекс физических методов, используемых не только для исследования горных пород, но и для контроля технического состояния буровых [4]. В зависимости от назначения, такие исследования подразделяются на две группы, а именно методы каротажа и петрофизики. В данной работе рассматривался гамма – каротаж, представленный в виде временного ряда. Такой вид каротажа применяется разных областях таких как оценка плотности пород, определение типов минералов, из которых состоит пласт, поиск содержания нефти и газа в горной породе, мониторинга качества скважин. Также допускает

проникновения излучения сквозь породу и дает информацию о составе на глубине.

На данный момент для разработки месторождения нужно построить куб геофизических атрибутов. В результате сейсморазведочных работ и привязке к каротажным данным. Но каротаж, в свою очередь, достаточно дорогая операция, так как для того, чтобы получить каротажные данные, приходится прекращать работу скважины, следовательно, компания несет денежные убытки от упущенной нефти, поэтому в этой работе предлагается метод прогнозирования куба геофизических атрибутов, то есть каротажа, в каждой точке пространства на основе уже имеющихся каротажных данных. Таким образом вместо замера каротажа в каждой скважине, становится возможным интерполяция данных по гораздо меньшему количеству замеренных каротажей.

Цель данной работы заключается в улучшении качества построения кубов геофизических атрибутов.

В соответствии с поставленной целью, решались следующие задачи:

1. Изучение актуальной литературы по данной теме.
2. Интерполяция гамма – каротажа рядом Фурье.
3. Интерполяция коэффициентов ряда Фурье по пространству.
4. Интерполяция гамма – каротажа нейронной сетью.
5. Интерполяция полученных коэффициентов нейронной сети по пространству.
6. Сравнение и анализ полученных двумя методами результатов.

ГЛАВА 1. ТЕОРЕТИЧЕСКИЕ ОСНОВЫ ГЕОФИЗИЧЕСКИХ ИССЛЕДОВАНИЙ

1.1. Роль геофизических методов в исследовании земной коры

В исследовании земной коры важную роль играют геофизические методы, которые предоставляют информацию о ее составе, структуре и динамических процессах. Для изучения земной коры, которая является верхним слоем литосферы, используются различные научные дисциплины, такие как геология, геофизика и геохимия. В то же время, именно геофизические методы дают возможность получать информацию о глубоких слоях коры от поверхностных слоев до глубин в несколько десятков километров, которые недоступны для прямого наблюдения.

На данный момент применяют такие геофизические методы исследования земной коры как:

1. Сейсмические методы: Среди наиболее эффективных инструментов исследования земной коры являются сейсмологические методы основаны на анализе волн, вызванных либо естественными источниками, такими как землетрясения, либо искусственными, такими как взрывы. К основным сейсмологическим методам относятся сейсмическая томография, рефракционная и отражательная сейсмика.

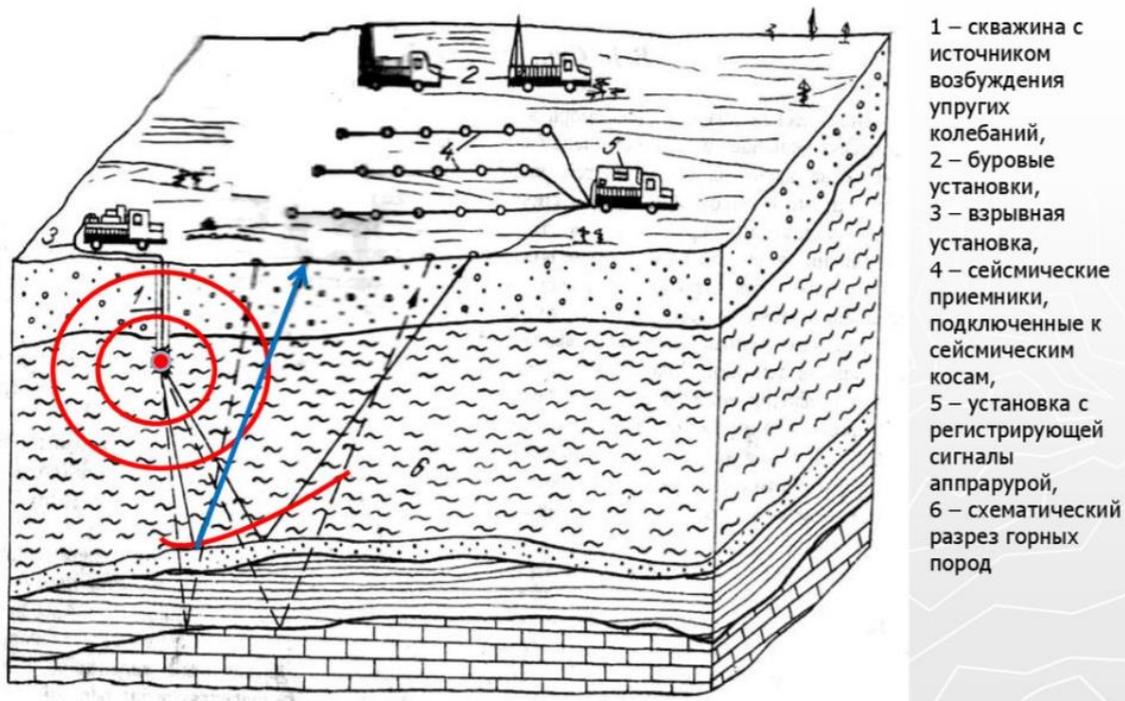


Рис.1. Схема сейсмических исследований.

1.1. Сейсмическая томография: Позволяет строить трехмерные модели земных недр, подобно тому как медицинская томография используется для получения изображений внутренних органов человека. Метод основан на измерении времени прохождения сейсмических волн через различные слои земной коры, что позволяет обнаружить изменения в плотности и других физических свойствах пород.

1.2. Рефракционная сейсмология: Рефракционная сейсмология в первую очередь связана с изучением верхней части земной коры. Основанный на анализе сейсмических волн, преломленных на границах между слоями, имеющими различную плотность, этот метод имеет большое значение для определения глубины залегания различных геологических структур под поверхностью земли - будь то осадочный бассейн или даже фундамент континента.

1.3. Отражательная сейсмология: Призвана получить более подробную информацию о строении земной коры на больших глубинах. Этот метод основан на регистрации сейсмических волн, отраженных от границ раздела слоев, отличающихся по своим физическим свойствам. Именно этот метод в настоящее время широко применяется в нефтегазовой отрасли для поиска и оценки месторождений углеводородов.

2. Гравиметрические методы: Один из основных методов поисковой геофизики - гравиметрия, или гравиразведка, нашел широкое применение при изучении глубинного строения земной коры и решении многих геологических задач. Метод предполагает изучение силы гравитационного поля Земли - естественного физического поля - и плотности горных пород. Он определяется своими измерениями в виде гравиметрических съемок различного масштаба, которые проводятся на суше, в шахтах и скважинах, в морях и океанах, а также из воздушного пространства.

Эти исследования носят гравиметрический характер и важны для обнаружения подземных структур и полезных ископаемых. Гравиметрические исследования также широко используются при изучении тектонических процессов - например, движения литосферных плит и образования горных хребтов. Современная гравиметрия обладает высокой чувствительностью и позволяет проводить измерения с высокой степенью точности как на земле, так и из космоса с помощью спутников.

3. Магнитные методы: В основе магнитометрии лежит измерение магнитного поля Земли и его аномалий, обусловленных наличием в земной коре магнитных минералов, например, магнетита. Магнитные методы широко используются при картировании структур недр,

преимущественно в районах с высокой концентрацией магнитных пород.

Магниторазведка позволяет определить особенности тектонических структур, таких как разломы и складки, найти рудные месторождения. Поэтому использование магнитометрии включает в себя поиск археологических объектов и исследование останков древних цивилизаций.

4. Электрические методы: Все они основаны на измерении электромагнитных полей, которые индуцируются в земной коре и исследуют ее электрические свойства.

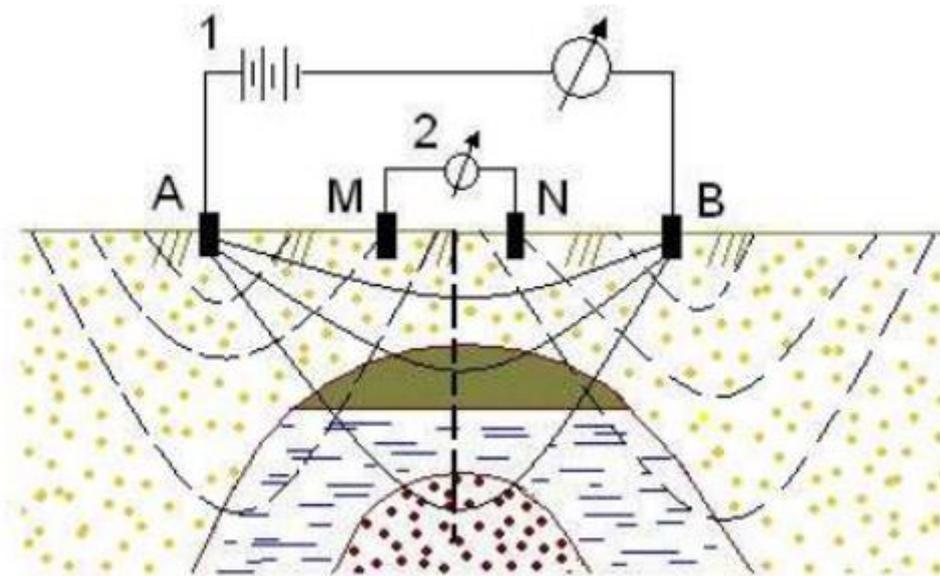


Рис.2. Схема электроразведки.

4.1. Магнитотеллурическое зондирование (МТЗ): Это исследование земной коры и верхней мантии с помощью естественных электромагнитных полей. Метод позволяет определить электропроводность различных слоев.

4.2. Метод электрического сопротивления: Метод основан на измерении сопротивления земных материалов прохождению через них электрического тока. Для измерения требуется четыре электрода: два для тока и два для измерения потенциала.

4.3. Метод электромагнитного зондирования (ЭМЗ): Этот метод использует искусственное внешнее электромагнитное поле для изучения земной коры.

5. Геотермические методы: Геотермальные методы основаны на измерении теплового потока и температуры в земной коре. Эти методы позволяют исследовать процессы теплообмена и тектоническую активность.

1.2. Виды геофизических атрибутов и их значения в нефтегазовой отрасли

Геофизические атрибуты являются основными инструментами в нефтегазовом секторе, предоставляя данные для интерпретации структуры недр, характеристики свойств горных пород, оценки и определения местоположения перспективных залежей углеводородов. Теперь давайте рассмотрим наиболее часто используемые типы геофизических атрибутов и их значение в нефтегазовой отрасли.

Основные методы геофизических атрибутов:

1. Сейсмические атрибуты: Основаны на анализе данных, полученных с помощью сейсморазведки; эти атрибуты позволяют определить структурные и стратиграфические характеристики подземных пород.

- **Амплитуда**: Измеряет величину сейсмического отклика. Высокие амплитуды указывают на границы между слоями с различными физическими свойствами, такими как плотность и пористость.

- **Время прибытия:** Используется при построении временных сейсмических разрезов, помогает определить глубину залегания различных геологических структур.
- **Фазовые атрибуты:** Анализ изменений фаз сейсмических волн используется для выявления литологических изменений и границ насыщения флюидами.
- **Коэффициент отражения:** Позволяет оценить контраст плотности и скорости сейсмических волн между различными пластами.

2. Гравиметрические атрибуты: Такой вид атрибутов измеряет вариации гравитационного поля Земли, вызванные изменениями плотности горных пород.

Гравитационные аномалии: изменения в гравитационном поле, указывающие на существование структур с различной плотностью - например, соляных куполов, осадочных бассейнов и складчатых зон.

3. Магнитные атрибуты: Магнитные атрибуты показывают на сколько изменено магнитное поле Земли, обусловленное наличием магнитных минералов.

4. Электрические атрибуты: Электромагнитные атрибуты связаны с измерением электромагнитных полей и их вариаций в земной коре [4].

- **Электрическая проводимость:** Измеряет способность горных пород проводить электричество. Чем выше электропроводность, тем насыщеннее водоносные горизонты или залежи углеводородов.
- **Реактивное сопротивление** - это способность породы противостоять переменному электромагнитному полю, что необходимо для определения типа породы и ее насыщенности.

5. Геотермические атрибуты: Геотермальные характеристики основаны на измерении теплового потока и температуры внутри земной коры.

Тепловой поток: Количество тепловой энергии, проходящей через единицу площади. Высокие значения могут указывать на наличие геотермальных аномалий, вызванных тектонической активностью или вулканизмом.

6. Каротажные методы: Методы каротажа скважин включают в себя измерение различных физических характеристик горных пород и жидкостей непосредственно в стволе скважины. Они передают детальную и немало важную информацию о пласте.

1.2.1. Значение геофизических атрибутов в нефтегазовой отрасли

Геофизические атрибуты позволяют выявить потенциальное существование ловушек нефти и газа, оценить размеры и характеристики месторождений, а также определить оптимальные точки для бурения.

Атрибуты позволяют отслеживать изменения в коллекторе, такие как движение флюидов и изменение давления, что играет определенную роль в повышении эффективности добычи и увеличении коэффициента извлечения.

Применение геофизических атрибутов снижает риски, которые могут появиться при бурении, такие как неожиданное обнаружение пустот, зон аномально высокого давления или других опасных условий.

Геофизические данные, полученные на месте, могут эффективно использоваться для планирования и проведения буровых работ, снижая затраты и повышая окупаемость проектов.

1.2.2. Каротажные методы

Каротаж - один из основных методов геофизического исследования скважин, широко применяемый в нефтегазовой отрасли. При котором в стволе скважины проводятся измерения ряда физических свойств горных пород и

флюидов. Эти измерения позволяют определить характеристики горных пород, определить их литологию, пористость, насыщенность флюидами и ряд других важных параметров. Рассмотрим, какие существуют основные методы каротажа и их значения.

Основные виды каротажных методов:

1. Электрический каротаж:

- Метод потенциалов самопроизвольной поляризации (ПС): Также известен как естественный электрический метод. Он основан на измерении естественных электрических потенциалов, возникающих в земной коре в результате электрохимических и электроосмотических процессов.

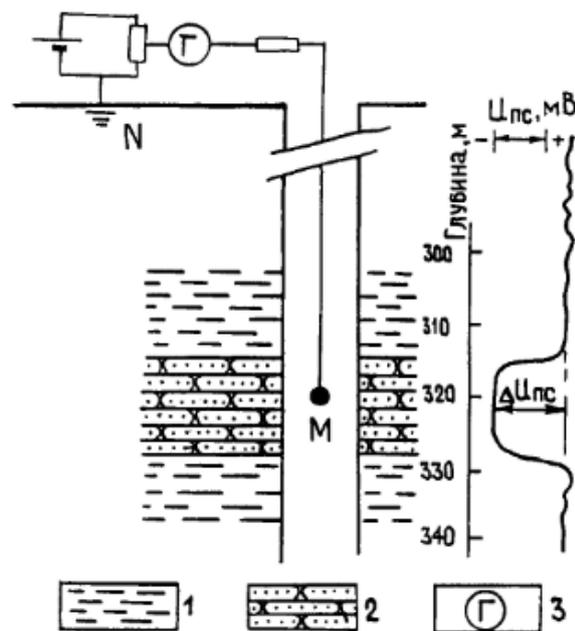


Рис. 3. Схема измерения ПС, где 1 – глина; 2 – песчаник; 3 – регистрирующий прибор

- Индукционный каротаж: Использование электромагнитных полей для измерения электропроводности горных пород. Этот метод очень эффективен при использовании высокоэлектропроводящего бурового раствора.

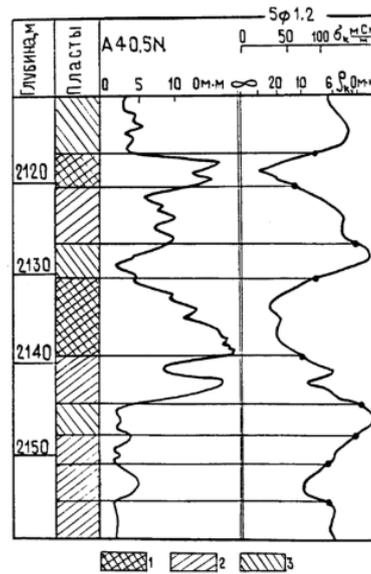


Рис.4. Индукционный каротаж, где 1–3 – пласты высокого, среднего и низкого удельного сопротивления соответственно.

2. Радиоактивный каротаж:

- Гамма-каротаж: Измеряет естественную гамма-активность горных пород. Используется для оценки содержания глинистых минералов.

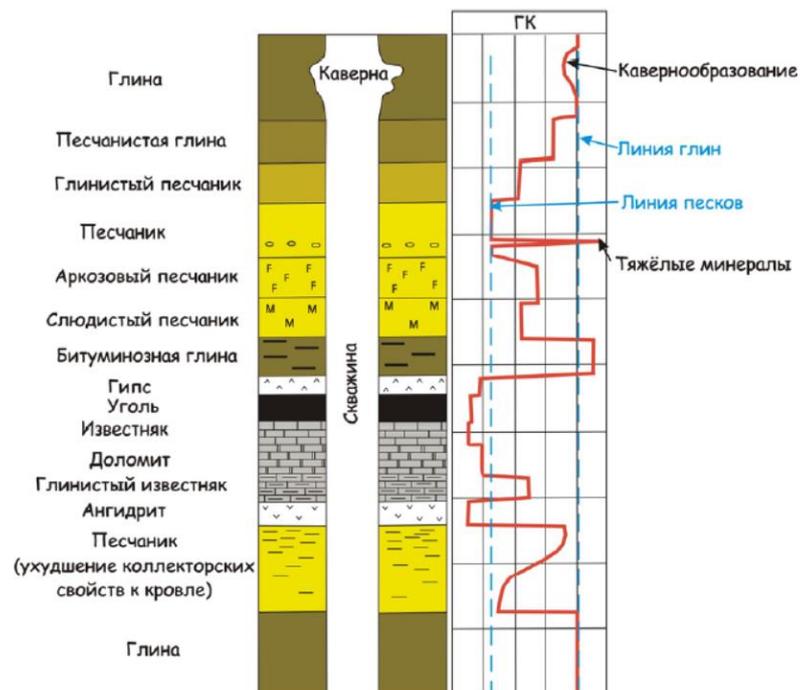


Рис. 5. Схема гамма-каротажа.

- Нейтронный каротаж: Измеряет содержание водорода в породах, позволяя оценить пористость и насыщенность пород флюидами.

- Гамма-гамма каротаж: Использование искусственных источников гамма-излучения для измерения плотности горных пород.
3. Акустический (сейсмический) каротаж: Измеряет скорость прохождения звуковых волн через горные породы. Используется для оценки пористости и механических свойств пород.
 4. Электромагнитный каротаж: ЭМ использует электромагнитное поле для измерения электропроводности и диэлектрических свойств пластов.
 5. Температурный каротаж: Измеряет температуру вдоль ствола скважины. Определяет приток и поток флюидов (нефть, газ, вода) в скважине.

Данные каротажа позволяют определить типы пород, например, песчаники, известняки, глины и т.д., их стратиграфию, измерить пористость и насыщенность пород флюидами (нефть, вода, газ), что в свою очередь позволяет оценить потенциальные запасы нефти и газа. Границы между водоносными и нефтеносными зонами определяются с помощью методов ГИС, что имеет немаловажное значение для определения планов добычи. Акустический каротаж скважин позволяет оценить упругость и прочность горных пород, что очень важно для бурения и проектирования эксплуатации скважин. Температурный и акустический каротаж помогает выявить притоки флюидов, потери в зонах циркуляции и другие аномалии в стволе скважины. Данные каротажа используются для корреляции разрезов скважин с сейсмическими данными и геологическими моделями, повышая точность интерпретации подповерхностных структур.

Геофизические атрибуты, в том числе каротажные, имеют важное значение в нефтегазовой отрасли. Они дают достаточно ценную информацию о физических свойствах пород и флюидов, что повышает оценку запасов углеводородов, позволяет более точно планировать бурение и оптимизировать

разработку месторождений. Развитие технологий и методов интерпретации данных продолжается, повышая эффективность и точность геофизических исследований, тем самым способствуя устойчивости развития и рационального использования природных ресурсов.

ГЛАВА 2. МЕТОД ИНТЕРПОЛЯЦИИ ГАММА – КАРОТАЖА РЯДОМ ФУРЬЕ

2.1. Постановка задачи

В нефтегазовой отрасли построение кубов геофизических атрибутов имеет важное значение для разработки, поскольку позволяет получить многомерную картину атрибутов пласта и помогает в интерпретации геологических структур. Ранее для построения таких кубов использовался спектральный метод, в рамках которого:

1. Каротажные кривые раскладываются в ряды, что позволяет получить параметризацию

$$G(X_c, Y_c, Z) = f(Z) \rightarrow \{a_1, a_2, \dots, a_n\}(X_c, Y_c), \quad (1)$$

Где X_c, Y_c – координаты скважин, G – геофизический атрибут.

2. Строятся двумерные карты параметров $\{a_1, a_2, \dots, a_n\}(X, Y)$ в межскважинном пространстве.
3. По значениям $\{a_1, a_2, \dots, a_n\}(X, Y)$ в каждой точке (X, Y) рассчитываются значения $G(X, Y, Z)$

2.2. Спектральный метод

Спектральный метод в нефтегазовой отрасли применяется в основном для обработки и интерпретации данных каротажа. Он основан на использовании рядов Фурье для частотного анализа данных и выявления скрытых особенностей в скважине.

Этот метод позволяет исследовать изменения физических свойств скважины в зависимости от глубины. Спектральный анализ позволяет выявить в данных каротажа гармонические составляющие, которые могут быть

связаны с различными геологическими структурами и характеристиками скважины.

В процессе спектрального анализа с помощью дискретного преобразования Фурье данные временного ряда разлагаются на гармонические составляющие с различными частотами. Последующая интерполяция полученных спектральных составляющих дает промежуточные значения данных каротажа на различных глубинах скважин.

Спектральный метод находит широкое применение в нефтегазовой промышленности для решения различных задач, связанных с определением пористости, проницаемости, насыщенности и других физических свойств скважины. Он также может быть использован для определения структуры и особенностей геологического пласта вокруг скважины.

Применение рядов Фурье в нефтегазовой отрасли имеет широкий спектр применения, охватывая различные аспекты геофизических исследований и анализа данных.

1. Сейсморазведка: Преобразование Фурье может эффективно реализовать выделение и удаление шумов из сейсмических данных. Получив данные в частотной области, можно выделить и устранить высокочастотный шум, мешающий интерпретации сигнала. Также анализ частотного спектра сейсмических данных с помощью преобразования Фурье позволяет выделить ряд геологических структур и слоев. Помимо этого, обратное преобразование Фурье может быть применено для создания моделей подповерхностных структур на основе частотных данных.
2. Каротажные исследования: Наличие периодических составляющих в каротажных данных можно определить с помощью преобразования Фурье, и это может указывать на повторяющиеся геологические пласты

или особенности. Применение преобразования Фурье для интерполяции и сглаживания каротажных кривых позволяет улучшить качество данных и их интерпретацию.

3. Мониторинг и диагностика оборудования: Использование быстрого преобразования Фурье для анализа вибрации оборудования позволяет своевременно получать информацию об износе и поломках. Преобразование временных рядов данных, таких как давление и температура, в частотную область с целью обнаружения аномалий и диагностики производственных проблем.

4. Построение моделей: Использование преобразования Фурье при помощи интерполяции и сглаживания данных позволяет создать модели подповерхностных структур более детально. А также для моделирования различных геофизических процессов, таких как распространение волн и тепловой поток.

2.2.1. Дискретное преобразование Фурье

Дискретное преобразование Фурье (ДПФ) – это математический метод, который применяется для анализа дискретных сигналов. Оно преобразует последовательность чисел, представляющих значения сигнала во времени, в последовательность чисел, представляющих амплитуды различных гармоник сигнала.

ДПФ представляется в виде:

$$S(k) = \sum_{n=0}^{N-1} s(n) e^{-j\frac{2\pi kn}{N}} = \sum_{i=0}^{N-1} s(n) \left[\cos \frac{2\pi kn}{N} - j \sin \frac{2\pi kn}{N} \right] \quad (2)$$

$$k = 0, \dots, N - 1.$$

ОДПФ из частотных составляющих позволяет синтезировать исходный сигнал. Такой процесс преобразования называется синтезом или обратным преобразованием Фурье. Заметим, что формулы обратного преобразования аналогичны формулам прямого преобразования, но теперь подынтегральной функцией являются коэффициенты синусов и косинусов. Это свойство очень важно и называется двойственностью преобразования Фурье.

$$s(n) = \frac{1}{N} \sum_{k=0}^{N-1} S(k) e^{j\frac{2\pi nk}{N}} = \frac{1}{N} \sum_{k=0}^{N-1} S(k) \left[\cos \frac{2\pi nk}{N} + j \sin \frac{2\pi nk}{N} \right] \quad (3)$$

$$n = 0, \dots, N - 1.$$

Что касается нефтяной промышленности, то в ней преобразование Фурье применяется в разведке при анализе и обработке сейсмических и других геофизических данных. Например, анализ сейсмических данных, преобразование Фурье позволяет выделить полезные сигналы из шума. В частотной области можно легко удалить или подавить шумы, не затрагивая важные данные; сейсмическая миграция этот процесс преобразует данные, собранные на поверхности, в изображение подповерхностных структур. Необходимость преобразования из временной области в частотную и наоборот может быть выполнена с помощью преобразования Фурье; анализ спектрального содержания, который дает возможность определить частотные характеристики сейсмических волн, являющиеся полезными для идентификации различных типов пород и жидкостей. Также преобразование Фурье используется в интерпретации данных, в численном моделировании волн, в создании изображений подземных объектов и структур.

Эти методы помогают геофизикам и инженерам-нефтяникам интерпретировать данные о подповерхностных структурах с гораздо большей точностью, что приводит к повышению эффективности разведки, добычи и управления ресурсами.

2.3. Интерполяция гамма-каротажа рядом Фурье

Для того, чтобы интерполировать гамма – каротаж по глубине, нужно получить коэффициенты Фурье. В данной работе это реализовано на языке программирования Python. Прежде чем начать, необходимо установить нужные библиотеки такие как SciPy, NumPy для работы с массивами, Matplotlib для визуализации данных, Lasio для чтения и записи файлов Log ASCII Standard (LAS), используемых для данных скважин, Pandas для обработки и анализа данных.

Сначала выполним обработку .las файлов [5], создаем DataFrame, в котором имеются название скважины, гамма – каротаж и глубина, принадлежащие определенной скважине.

Далее рассмотрим одну скважину и произведем обработку .las файлов. Основываясь на созданном DataFrame выбираем скважину, ее глубину и данные гамма – каротажа.

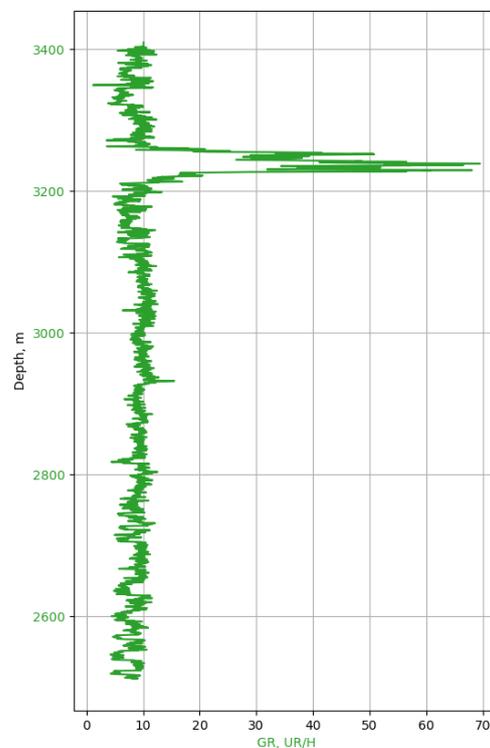


Рис.6. График гамма – каротажа одной скважины.

Теперь используя дискретное и обратное дискретное преобразование Фурье гамма – каротажа, при помощи встроенной функции DCT и IDCT получим первые 50 коэффициентов каротажа. DCT демонстрирует «свойство сжатия энергии», что означает, что для многих сигналов только первые несколько коэффициентов DCT имеют значительную величину. Обнуление остальных коэффициентов приводит к небольшой ошибке восстановления, и этот факт используется при сжатии сигнала с потерями (например, сжатии JPEG).

7.46213699	7.46651725	7.47519268	7.48799439	7.50467202
7.52489746	7.54826954	7.57432003	7.60252054	7.63229058
7.66300642	7.69401095	7.72462415	7.75415427	7.78190951
7.80721	7.8294001	7.84786059	7.86202082	7.87137046
7.87547074	7.87396496	7.86658796	7.85317461	7.83366676
7.80811882	7.77670157	7.73970406	7.69753367	7.65071393
7.59988027	7.54577363	7.48923173	7.43117839	7.37261067
7.31458417	7.25819654	7.20456953	7.15482974	7.11008842
7.07142066	7.03984432	7.01629905	7.00162584	6.99654756
7.00165079	7.01736937	7.0439702	7.08154141	7.12998349

Таблица 1. Первые 50 коэффициентов Фурье гамма – каротажа.

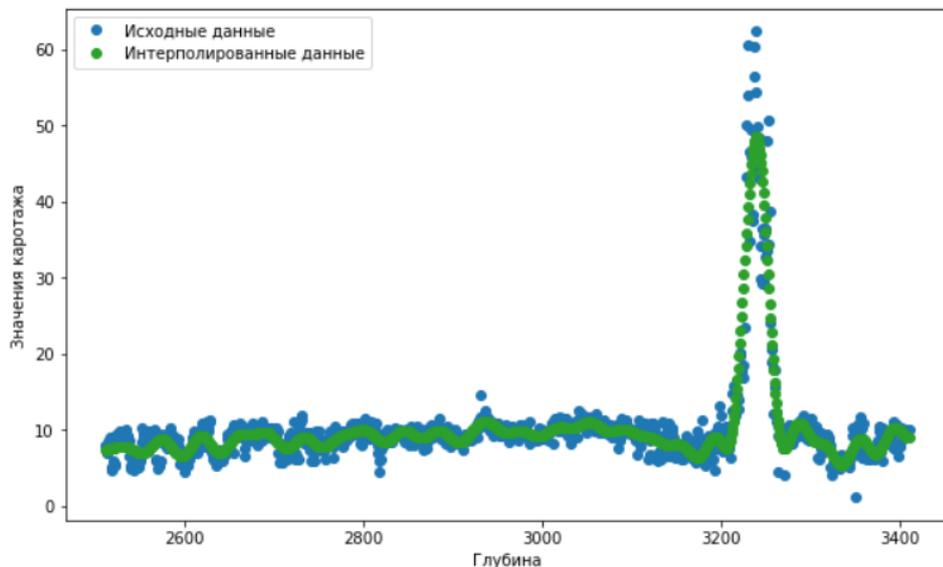


Рис. 7. Иллюстрация интерполяции гамма-каротажа рядом Фурье одной скважины.

Для того, чтобы выявить взаимосвязи между двумя результатами, обнаружить ошибки в данных или интересные особенности, понять каким образом распределены данные, оценить расхождение полученных результатов необходимо построить кросс – плот (рисунок 8)

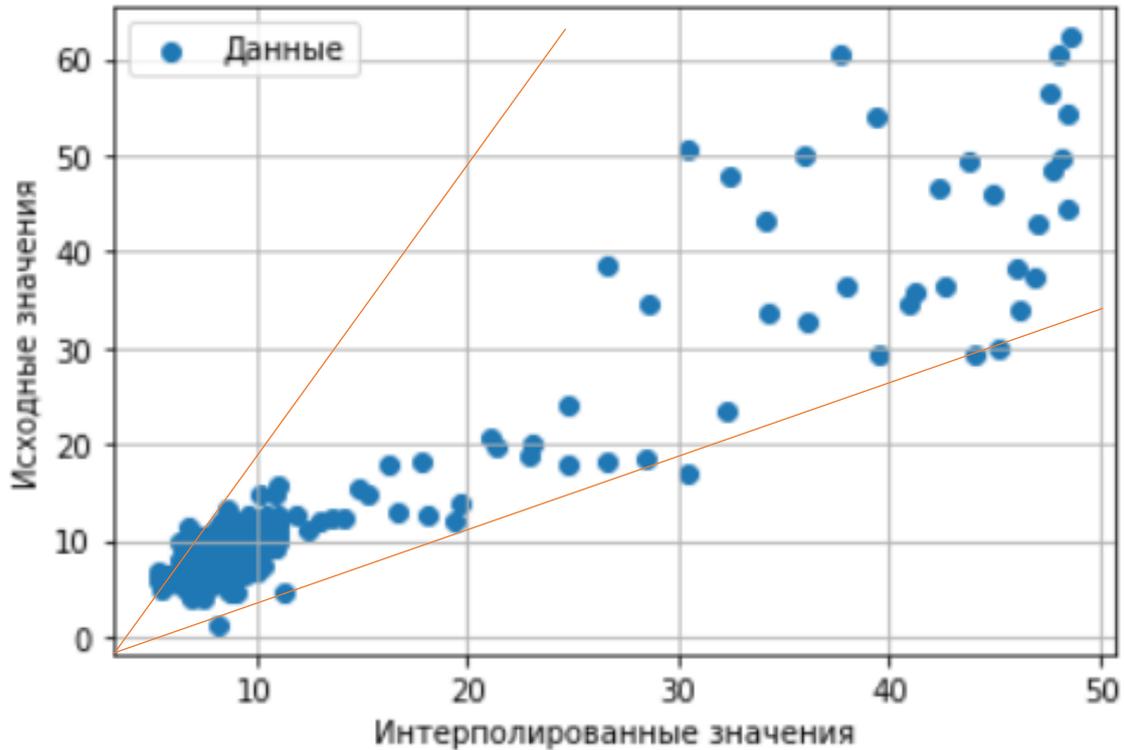


Рис. 8. Кросс – плот интерполированных и исходных значений.

Также приведена таблица метрик:

Метрика	Значение
MAE	1.2806
R2	0.8696
MARE	13.121%

Таблица 2. Метрики качества модели.

Где *MAE* (Mean Absolute Error) - измеряет среднюю величину ошибок между предсказанными значениями и фактическими значениями. Это простой способ измерить точность модели. Ошибка для каждого примера берется по модулю, что позволяет избежать проблем с компенсацией ошибок разных знаков.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (4)$$

y_i – фактическое значение, \hat{y}_i – предсказанное значение,

n – количество наблюдений.

MAPE (Mean Absolute Percentage Error) - измеряет среднюю величину абсолютных ошибок в процентах от фактических значений.

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (5)$$

R2 – или коэффициент детерминации показывает, насколько хорошо предсказания модели соответствуют реальным данным. Значение R2 варьируется от 0 до 1. Чем ближе значение R2 к единице, тем точнее модель.

Формула для вычисления R2 следующая:

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \quad (6)$$

$$SS_{res} \text{ (Residual Sum of Squares)} = \sum (y_i - f_i)^2 \quad (7)$$

$$SS_{tot} \text{ (Total Sum of Squares)} = \sum (y_i - \bar{y})^2 \quad (8)$$

y_i – реальные значения, f_i – предсказанные значения,

\bar{y} – среднее значение реальных данных.

2.4. Интерполяция коэффициентов Фурье по пространству

Интерполяция пространства - это процесс оценки значения функции в точке, в которой не проводились измерения, но для которой доступны значения функции в других точках пространства. Этот метод интерполяции находит применение в геофизике, картографии, компьютерной графике и многих других смежных областях.

Что касается проблем в области нефти и газа, то пространственная интерполяция часто используется для реконструкции моделей недр по сейсмическим и другим геофизическим данным.

Для интерполяции по пространству используется CloughTocher2DInterpolator - это метод двумерной интерполяции, входящий в состав библиотеки SciPy. Метод эффективен для плавной интерполяции по сетке с использованием кусочно-гладких полиномов, которые также известны как кубические сплайны. Он особенно полезен, когда требуется точная и гладкая интерполяция в сложных областях с нерегулярно распределенными точками данных. Более подробно алгоритм метода описан в [15, 17].

Для этой части данной работы нам потребуются координаты скважины. Создаем новый DataFrame с названиями скважин, значениями минимальной и максимальной глубин и первыми 50 коэффициентами, полученные при помощи преобразования Фурье. Затем используя CloughTocher2DInterpolator, формируем интерполятор с сеткой, в которой прописываем значения столбцов координат X и Y. И интерполируем, в результате получаем:

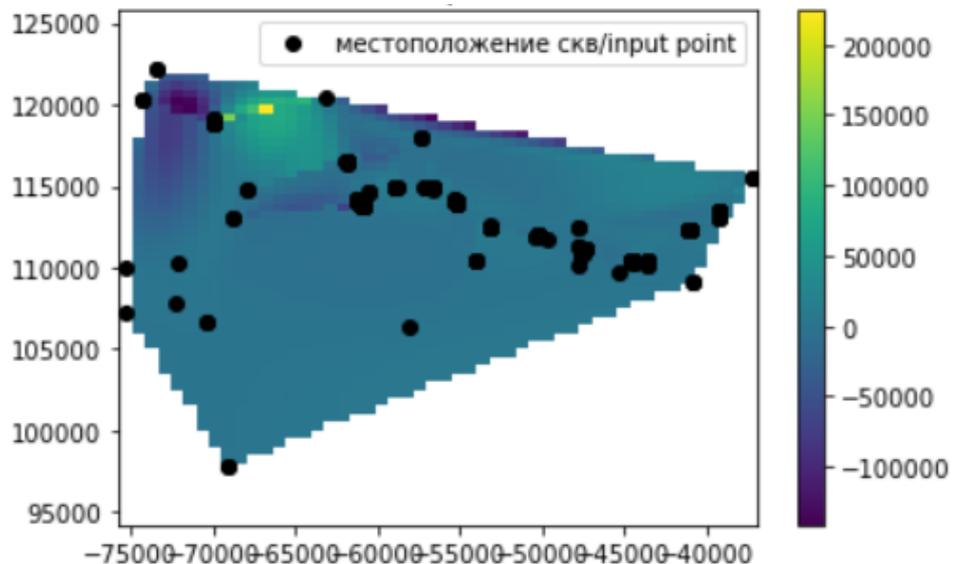


Рис. 9. Иллюстрация интерполяции первого коэффициента Фурье по пространству всех скважин.

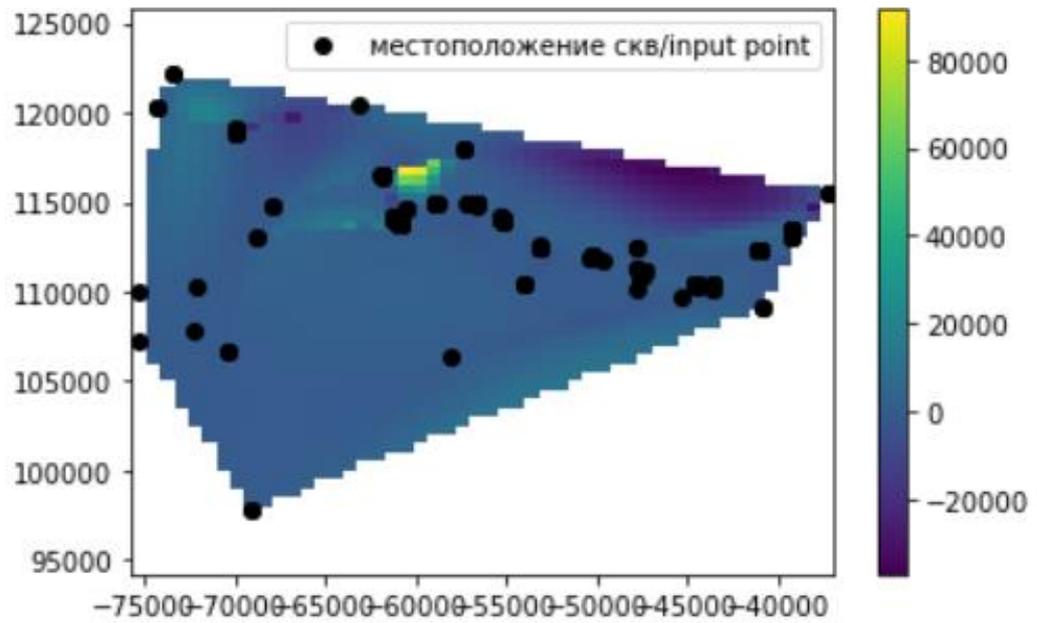


Рис. 10. Иллюстрация интерполяции второго коэффициента Фурье по пространству всех скважин.

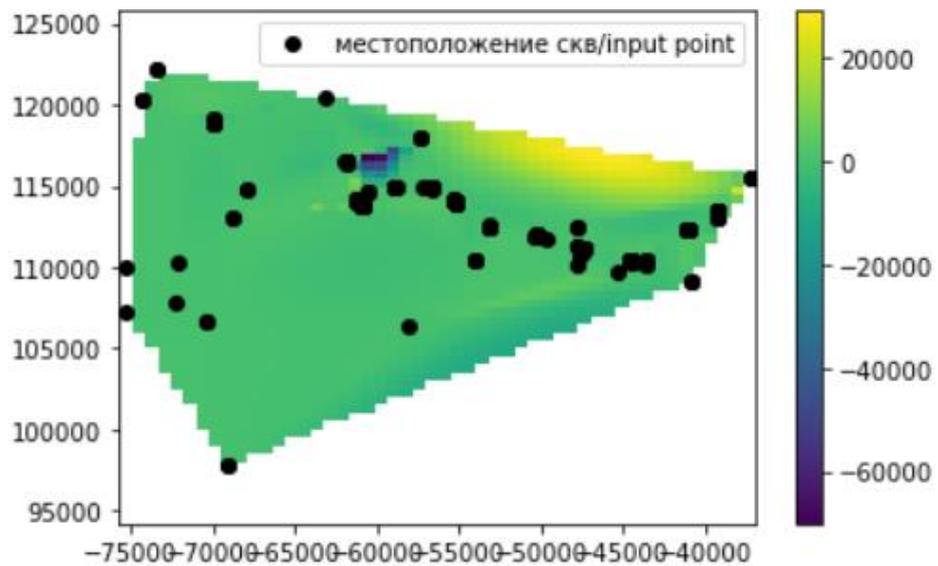


Рис. 11. Иллюстрация интерполяции третьего коэффициента Фурье по пространству всех скважин.

Остальные 47 коэффициентов имеют аналогичные иллюстрации.

Оценим расхождение полученных результатов построением кросс – плота (рисунок 12).

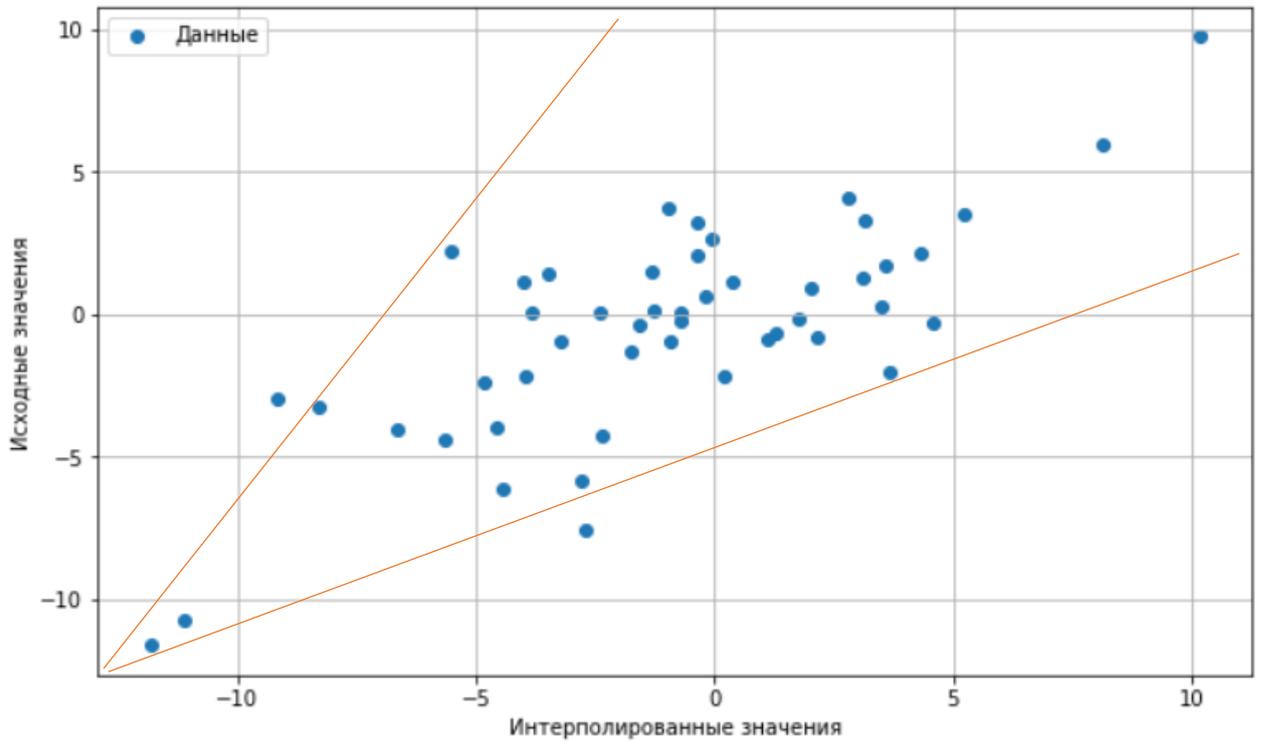


Рис. 12. Кросс – плот интерполированных и исходных значений.

Также приведена таблица метрик:

Метрика	Значение
MAE	2.4094
RMSE	2.9749
MAPE	16.238%
L2_norm	20.8245

Таблица 3. Метрики качества модели.

Где *MAE* (Mean Absolute Error), *MAPE* (Mean Absolute Percentage Error) вычисляются аналогично формулам (4), (5).

RMSE (Root Mean Square Error) - измеряет среднюю величину ошибок между предсказанными значениями и фактическими значениями. В отличие от *MAE*,

RMSE чувствителен к большим ошибкам, поскольку ошибки возводятся в квадрат.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (9)$$

y_i – фактическое значение, \hat{y}_i – предсказанное значение,
 n – количество наблюдений.

Вторая норма (L2_norm или Евклидова норма) разности двух векторов — это квадратный корень из суммы квадратов разностей их соответствующих элементов. Это также называется расстоянием между двумя векторами в пространстве.

$$L2_{norm} = \|y_i - \hat{y}_i\|_2 = \sqrt{\sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (10)$$

ГЛАВА 3. ПОСТРОЕНИЕ КУБОВ ГЕОФИЗИЧЕСКИХ АТТРИБУТОВ С ИСПОЛЬЗОВАНИЕМ НЕЙРОСЕТЕВЫХ МЕТОДОВ

3.1. Использование нейросетей для предсказания и интерпретации геофизических атрибутов

Использование нейронных сетей для прогнозирования и интерпретации геофизических атрибутов оказалось одним из ключевых направлений в геофизике и нефтегазовой промышленности. Это объясняется высокой сложностью данных и необходимостью автоматизации и повышения точности прогноза. В таком случае нейронные сети применяются для решения различных задач, таких как интерпретация сейсмических данных, прогнозирование свойств горных пород, оценка насыщенности флюидов и других.

Нейронные сети могут обрабатывать и анализировать большие объемы информации автоматически, что снижает трудозатраты и значительно ускоряет рабочий процесс. Современные модели нейронных сетей - глубокие нейронные сети (DNN), сверточные нейронные сети (CNN) и рекуррентные нейронные сети (RNN) - способны анализировать сложные взаимосвязи между данными и обеспечивать высокую точность прогнозирования [10]. Нейронные сети можно обучать на данных, характерных для той или иной области, что позволяет адаптировать модели к конкретным условиям и особенностям. Нейронные сети могут объединять данные из различных источников, таких как сейсмические, каротажные и петрофизические, для более полной и точной интерпретации. Например, CNN применяются для классификации сейсмических изображений и выделения различных геологических фаций. Такие модели, как RNN и другие, могут применяться для оценки насыщенности нефтью, газом и водой. Кроме того, нейронные сети позволяют интерпретировать несколько типов каротажных данных, включая электрический, акустический и нейтронный каротаж.

3.2. Виды нейронных сетей

Нейронные сети - это вычислительные модели, созданные на основе биологических нейронов, способные обучаться и принимать решения на основе данных. Они составляют основу науки машинного обучения и искусственного интеллекта и применяются в широком спектре приложений, от обработки изображений до анализа текстов и временных рядов [13].

К основным компонентам нейронных сетей относятся:

1. Входные нейроны (узлы): базовый строительный блок, каждый из которых получает входные данные, обрабатывает их с помощью весов и функции активации и выдает на выходе результат.
2. Весовые коэффициенты (Weights): Каждое соединение нейронов имеет вес - показатель того, насколько важен входной сигнал от предыдущего нейрона. В процессе обучения веса корректируются, чтобы уменьшить ошибку.
3. Функция активации (Activation Function): Функция, применяемая к сумме взвешенных входов нейрона и определяющая его выходное значение. Некоторые примеры включают ReLU, сигмоид и гиперболический тангенс.
4. Слои: Нейронные сети состоят из слоев нейронов:

Входной слой (Input Layer): Получает начальные данные.

Скрытые слои (Hidden Layers): Один или несколько слоев, которые обрабатывают данные между входом и выходом.

Выходной слой (Output Layer): Производит окончательные выходные значения.

Принцип работы нейронных сетей заключается в:

- Прямое распространение (Forward Propagation): Данные движутся по сети от входного слоя к выходному, при этом веса и функции активации применяются на каждом слое для получения

промежуточных результатов и конечного выхода.

- Функция потерь (Loss Function): Вычисляется разница между предсказанными выходными значениями и реальными метками. Например, средняя квадратичная ошибка для регрессии и перекрестная энтропия для классификации.
- Обратное распространение (Backpropagation): Это алгоритм, который использует градиенты функции потерь для корректировки весов при переходе от выходного слоя обратно к входному. Этот процесс позволяет уменьшить ошибку модели.
- Обновление весов (Weight Update): Весы обновляются с помощью методов оптимизации, таких как стохастический градиентный спуск, или его разновидностей, таких как Adam, RMSprop.

Существуют разные виды нейронных сетей таких как

1. Прямые нейронные сети (Feedforward Neural Networks): Информация поступает только в одном направлении - от входа к выходу. Пример: Многослойный перцептрон, MLP [13].
2. Сверточные нейронные сети (Convolutional Neural Networks, CNN): Они используются для обработки изображений и видео с помощью сверки слоев, которые впоследствии извлекают особенности.
3. Рекуррентные нейронные сети (Recurrent Neural Networks, RNN): Они обрабатывают последовательные данные, такие как временные ряды или текст, используя циклы для запоминания информации о предыдущих шагах.
4. Генеративно-состязательные сети (Generative Adversarial Networks, GAN): Это сети, состоящие из генератора и дискриминатора, которые конкурируют друг с другом для получения реалистичных данных.
5. Графовые нейронные сети (Graph Neural Networks, GNN): Они обрабатывают данные, представленные в виде графов, применяя графовые сверточные операции.

б. Трансформеры (Transformers): Они обрабатывают последовательные данные параллельно и улавливают долгосрочные зависимости без использования рекуррентных связей.

Нейронные сети имеют широко применение в разных областях таких как, обработка изображений и видео (классификация изображений, обнаружение объектов, распознавание образов), обработка естественного языка (перевод текста, анализ настроения, генерация текста), анализ временных рядов (прогнозирование финансовых данных и погодных условий), медицина (диагностика заболеваний, анализ медицинских изображений), автономные системы (автономное вождение, робототехника).

3.2.1. Архитектура нейронных сетей

Архитектура нейронных сетей определяет, как нейроны и слои организованы и взаимодействуют между собой. Различные архитектуры предназначены для решения специфических задач и обладают уникальными свойствами. Рассмотрим основные типы архитектур нейронных сетей и их особенности [10]:

1. Прямые нейронные сети (Feedforward Neural Networks, FNN):

- Прямая передача сигналов: Информация передается в одном направлении от входного слоя к выходному через один или несколько скрытых слоев (рисунок 11).

2. Сверточные нейронные сети (Convolutional Neural Networks, CNN):

- Сверточные слои: Используют фильтры (ядра) для свертки с входными данными, выявляя пространственные признаки, такие как края и текстуры.
- Слои объединения (Pooling Layers): Уменьшают размерность данных, сохраняя важные признаки.
- Полносвязные слои (Fully Connected Layers): Окончательно классифицируют или регрессируют признаки, извлеченные сверточными слоями.

3. Рекуррентные нейронные сети (Recurrent Neural Networks, RNN):

- Рекуррентные связи: Нейроны соединены так, что их выходы на предыдущем шаге времени могут быть входами на текущем шаге.
- Память: Учитывают последовательную природу данных, что позволяет запоминать информацию о предыдущих шагах.

4. Генеративно-состязательные сети (Generative Adversarial Networks, GAN):

- Два компонента: Генератор, создающий фальшивые данные, и дискриминатор, отличающий реальные данные от фальшивых.
- Соревновательный процесс: Обе сети обучаются одновременно, улучшая свои способности генерировать и распознавать данные.

5. Автоэнкодеры (Autoencoders):

- Симметричная архитектура: Состоит из кодировщика (encoder), который сжимает входные данные в компактное представление, и декодировщика (decoder), который восстанавливает данные из этого представления.

6. Графовые нейронные сети (Graph Neural Networks, GNN):

- Обработка графов: Модели работают с данными, представленными в виде графов, где узлы и ребра могут иметь различные значения.
- Свертка на графах: Применение сверточных операций для извлечения признаков из графовых структур.

7. Трансформеры (Transformers):

- Механизм внимания (Attention Mechanism): Позволяет модели учитывать различные части входных данных с разной степенью важности.
- Параллельная обработка: Обработывают все элементы последовательности одновременно, что ускоряет обучение и

предсказание.

8. Резервуарные вычислительные сети (Reservoir Computing Networks):

- Фиксированный резервуар: Используют фиксированный, случайно инициализированный резервуар для преобразования входных данных в высокоразмерное пространство.
- Чтение выходов: Простая модель обучается на выходах резервуара для выполнения конечной задачи.

Оптимальная архитектура позволяет эффективно решать задачи, обеспечивая высокую точность и производительность модели.

В данной работе рассматривалась полносвязная нейронная сеть, которая широко используется в задачах прогнозирования временных рядов.

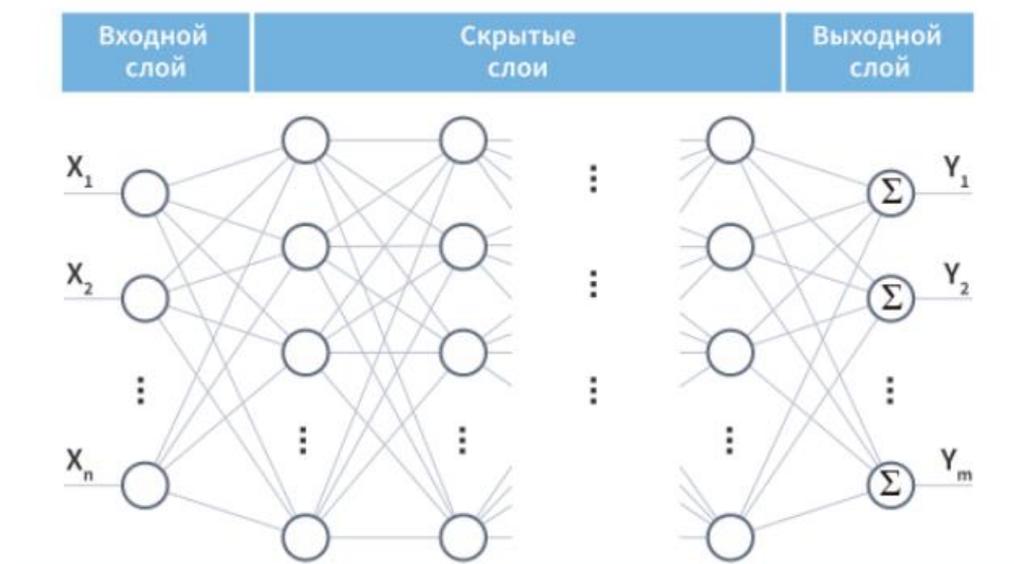


Рис. 13. Схема многослойной нейронной сети.

3.3. Постановка задачи

В пункте 2.1. рассматривалась постановка задачи уже существующего метода интерполяции коэффициентов ряда Фурье по пространству. На данном этапе предлагается несколько иной подход:

1. Каротажные кривые представляются в виде нейронных сетей определенной архитектуры с параметрами $a_1, a_2 \dots$:

$$G(X_c, Y_c, Z) = f(Z) \rightarrow \{a_1, a_2, \dots, a_n\}(X_c, Y_c), \quad (11)$$

Где X_c, Y_c – координаты скважин, G – геофизический атрибут.

2. Строятся двумерные карты параметров $\{a_1, a_2, \dots, a_n\}(X, Y)$ в межскважинном пространстве.
3. По значениям $\{a_1, a_2, \dots, a_n\}(X, Y)$ в каждой точке (X, Y) рассчитываются значения $G(X, Y, Z)$.

Нейрон имеет строение, показанное на рисунке (14) и вычисляет взвешенную сумму своих входов:

$$y(x) = f \left(\sum_{i=1}^d \omega_i x_i + w \right), \quad (12)$$

где x_i – входные данные, ω_i – весовые функции, w – сдвиг (весовые коэффициенты). Для удобства входной вектор расширяется до $x = (x_1, \dots, x_d)$.

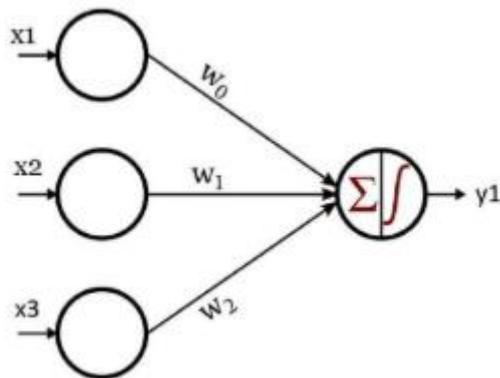


Рис. 14. Строение нейрона.

3.4. Предсказание коэффициентов геофизического атрибута при помощи полносвязной нейронной сети

Для интерполяции гамма – каротаж по глубине, нужно получить спрогнозированные коэффициенты нейронной сети. В данной работе это реализовано на языке программирования Python. Прежде чем начать, необходимо установить нужные библиотеки такие как SciPy, NumPy для работы с массивами, Matplotlib для визуализации данных, Lasio для чтения и записи файлов Log ASCII Standard (LAS), используемых для данных скважин,

Pandas для обработки и анализа данных, Scikit-learn для различных задач машинного обучения, включая классификацию, регрессию, кластеризацию, предварительную обработку данных, снижение размерности и оценку моделей и TensorFlow для решения задач построения и тренировки нейронной сети.

Для начала выберем одну скважину и реализуем метод прогнозирования значений гамма-каротажа нейронными сетями. Для этого разделим входные данные (гамма – каротаж) на тестовую и обучающую выборки при помощи встроенной функции `train_test_split` из библиотеки `sklearn.model_selection`. `X_train`: обучающая выборка для данных `X`. `X_test`: тестовая выборка для данных `X`. `y_train`: обучающая выборка для целевых значений `y`. `y_test`: тестовая выборка для целевых значений `y`.

Ставим `test_size=0.2`: 20% данных будет отведено для тестового набора, остальные 80% — для обучающего. Далее переходим к созданию модели, используя `Sequential`: это класс из Keras (библиотека для построения и обучения моделей глубокого обучения, работающая поверх низкоуровневых библиотек, таких как TensorFlow, Theano и CNTK), который используется для создания линейной модели, где слои добавляются последовательно. Добавляем входной слой и первый скрытый, используя `Dense(64)`: создаёт полносвязный (dense) слой с 64 нейронами, задаем размер входного слоя, равный количеству признаков в `X_train_scaled`, используем функцию активации ReLU (Rectified Linear Unit).

Выбор именно этой функции активации обосновывается своей простотой и эффективностью. Она определена следующим образом:

$$ReLU(x) = \max(0, x) \quad (13)$$

Это означает, что выход функции равен входному значению, если оно положительно, и нулю, если оно отрицательно.

После выбора функции активации добавляем 2 скрытых с 128 нейронами и выходной слой, в котором количество нейронов равно количеству целевых переменных в `y_train_scaled`. Компилируем модель при помощи оптимизатора `adam` (поддерживает адаптивные скорости обучения для каждого параметра, а также использует моменты для улучшения сходимости).

После обучения модели необходимо ее оценить, это делается методом `evaluate`, который используется для оценки производительности модели на тестовых данных. Теперь применяя `model.predict(X_test_scaled)`, прогнозируем целевые значения для тестового набора данных с помощью обученной модели, затем используя `scaler_y.inverse_transform(y_pred_scaled)`, обратно преобразует масштабированные прогнозы `y_pred_scaled` в исходную шкалу. Обучив модель, на выходе получаем набор коэффициентов и структуру слоев нейронной сети, изображенных на рисунке 15:

```
[<KerasVariable shape=(1, 64), dtype=float32, path=sequential/dense/kernel>,
 <KerasVariable shape=(64,), dtype=float32, path=sequential/dense/bias>,
 <KerasVariable shape=(64, 128), dtype=float32, path=sequential/dense_1/kernel>,
 <KerasVariable shape=(128,), dtype=float32, path=sequential/dense_1/bias>,
 <KerasVariable shape=(128, 128), dtype=float32, path=sequential/dense_2/kernel>,
 <KerasVariable shape=(128,), dtype=float32, path=sequential/dense_2/bias>,
 <KerasVariable shape=(128, 1), dtype=float32, path=sequential/dense_3/kernel>,
 <KerasVariable shape=(1,), dtype=float32, path=sequential/dense_3/bias>]
```

Рис. 15. Структура нейронной сети, `kernel` – ядро матриц весовых функций, `bias` – слой весовых коэффициентов.

-0.16619226	-0.23626208	0.1591944	0.11488319	0.2233989
0.3028542	-0.17688814	-0.19402081	-0.01139417	0.28384784
-0.21332559	-0.14523265	-0.04240763	0.18554373	-0.0206951
-0.46133733	-0.27056146	-0.01605558	-0.16829331	0.21308616
0.21408153	0.12917265	0.19452718	0.20336308	0.02896443
-0.13620439	-0.2581579	-0.14979516	-0.25610998	-0.20038055
0.23671891	-0.13988502	-0.20135514	0.22978352	-0.19600384
-0.26567692	-0.17670977	0.16483442	-0.17426217	0.1691178

-0.33195844	-0.00176939	-0.24308364	0.35497177	-0.31101096
-0.26163557	-0.06809213	0.23921455	0.23958388	0.1368557
-0.3180666	-0.16341284	0.32111946	-0.05792841	0.21730386
-0.33693045	0.21301705	-0.3001801	-0.36580583	0.73996841

Таблица 4. Ядро весовых функций входного слоя.

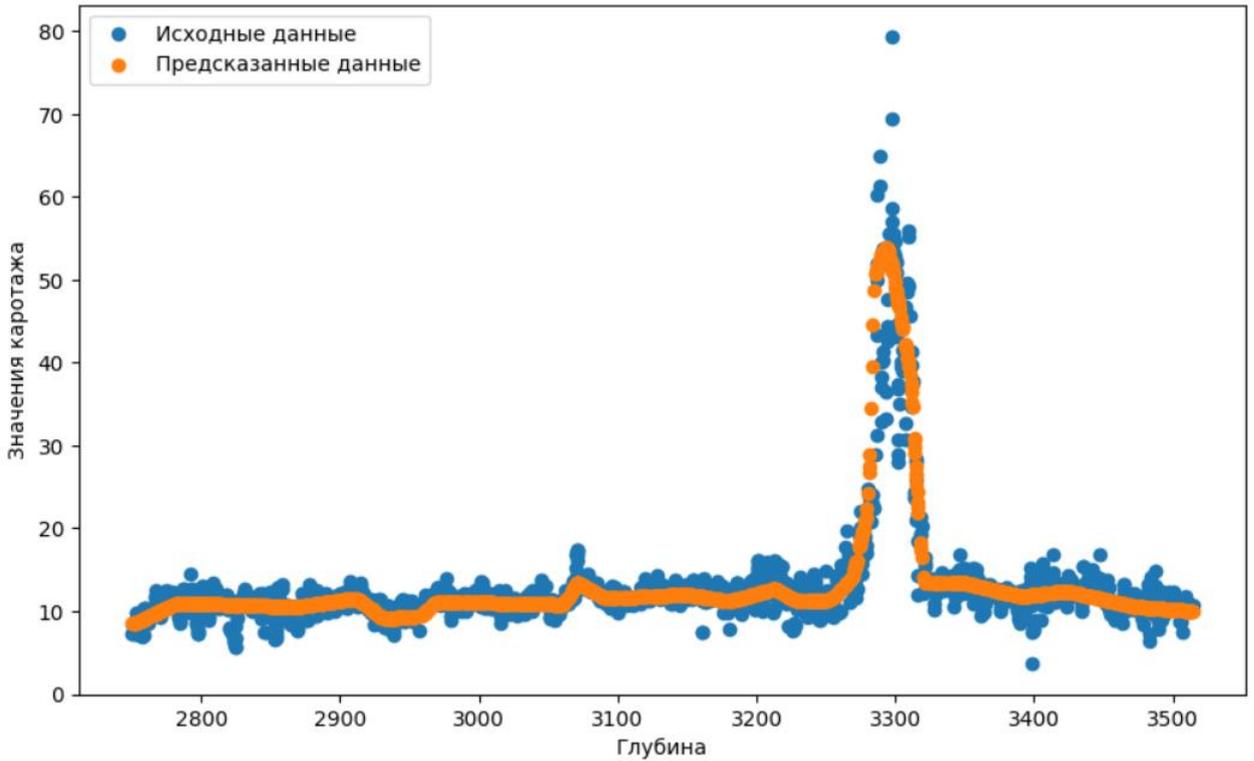


Рис. 16. Иллюстрация восстановления значений гамма – каротажа с помощью нейронной сети.

Аналогично параграфу 2.3 строится кросс – плот на основе реальных и прогнозированных значений.

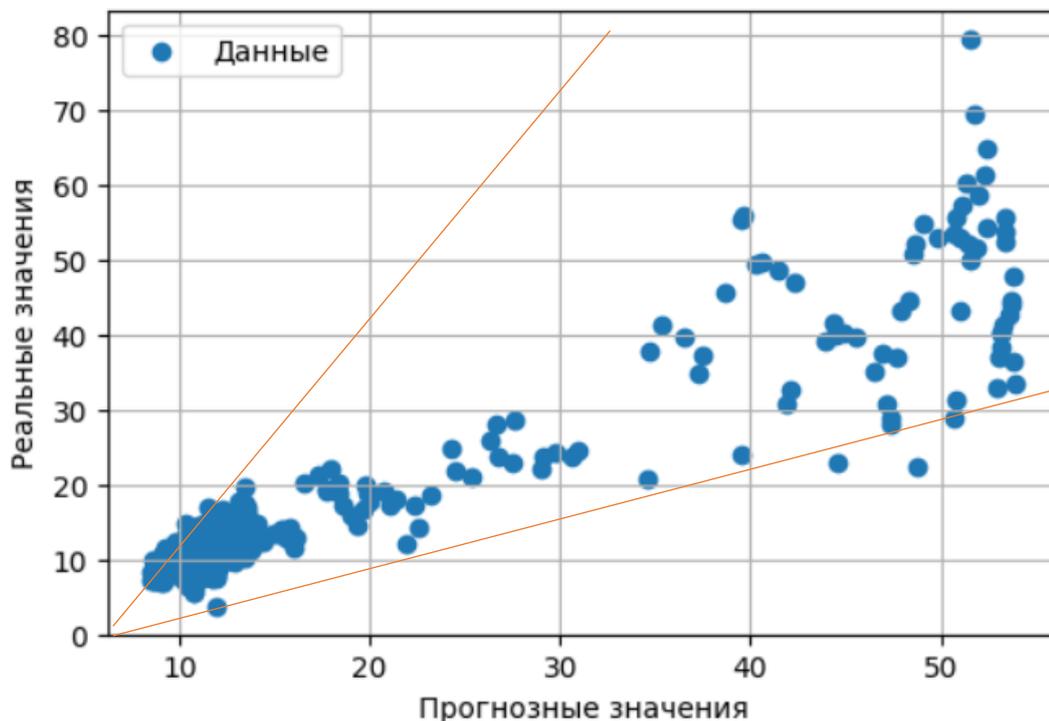


Рис. 17. Кросс – плот прогнозных и реальных значений.

Для оценки нейросетевой модели построим таблицу метрик, посчитанных по формулам MAE (4), MAPE (5), R2 (6):

Метрика	Значение
MAE	1.5307
R2	0.8481
MAPE	11.690%

Таблица 5. Метрики качества модели.

3.5. Интерполирование коэффициентов нейронной сети по пространству

Для интерполяции по пространству используется тот же метод CloughTocher2DInterpolator, что и в параграфе 2.4.

В этом параграфе нам потребуются также координаты скважины для создания нового DataFrame с их названиями, значениями минимальной и

максимальной глубин, но только теперь с весовыми коэффициентами входного слоя, полученные прогнозированием нейросетью. Затем выполняя все те же шаги, что и в 2.4., интерполируем, в результате получаем:

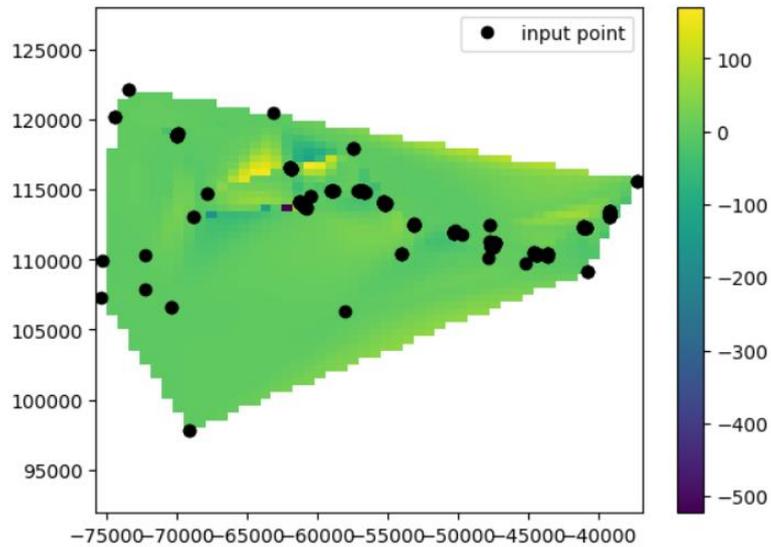


Рис. 18. Иллюстрация интерполяции первого весового коэффициента по пространству всех скважин.

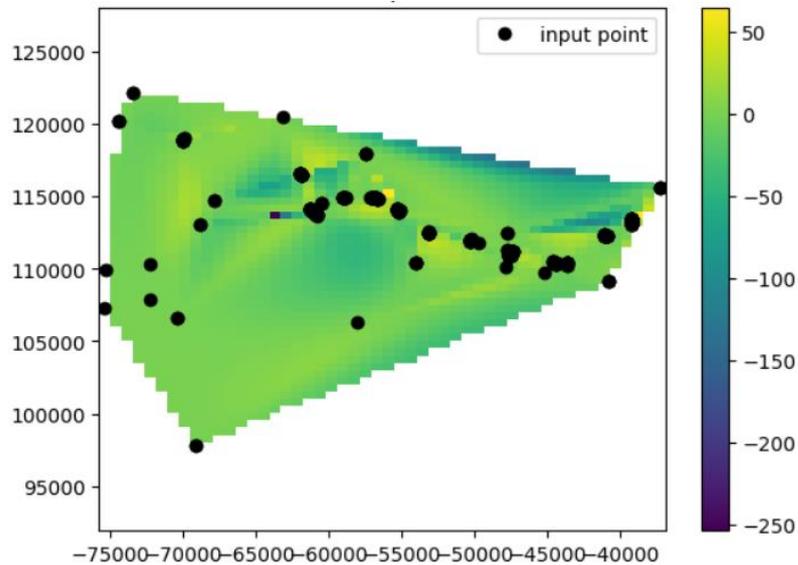


Рис. 19. Иллюстрация интерполяции второго весового коэффициента по пространству всех скважин.

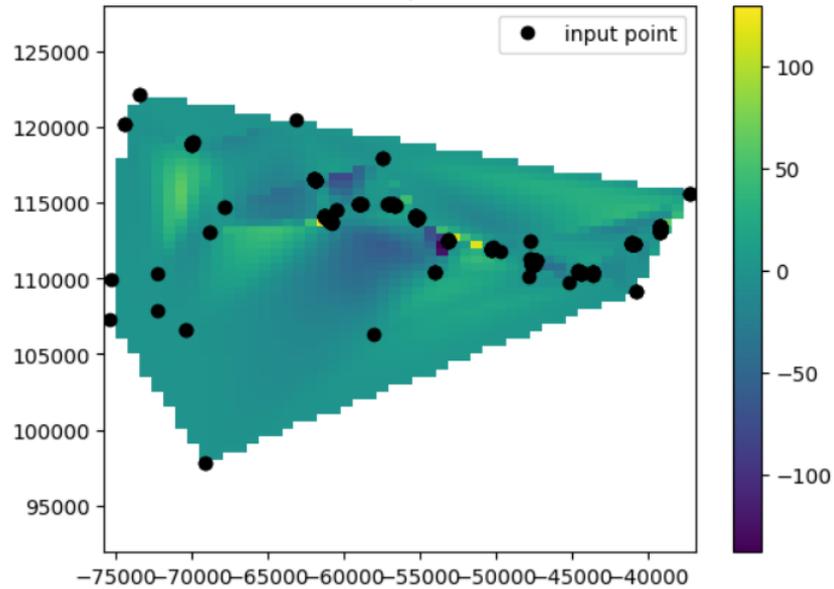


Рис. 20. Иллюстрация интерполяции третьего весового коэффициента по пространству всех скважин.

Остальные 47 коэффициентов имеют аналогичные иллюстрации трем первым.

Для того, чтобы оценить насколько прогнозные значения расходятся или сходятся с реальными значениями, необходимо построить кросс – плот.

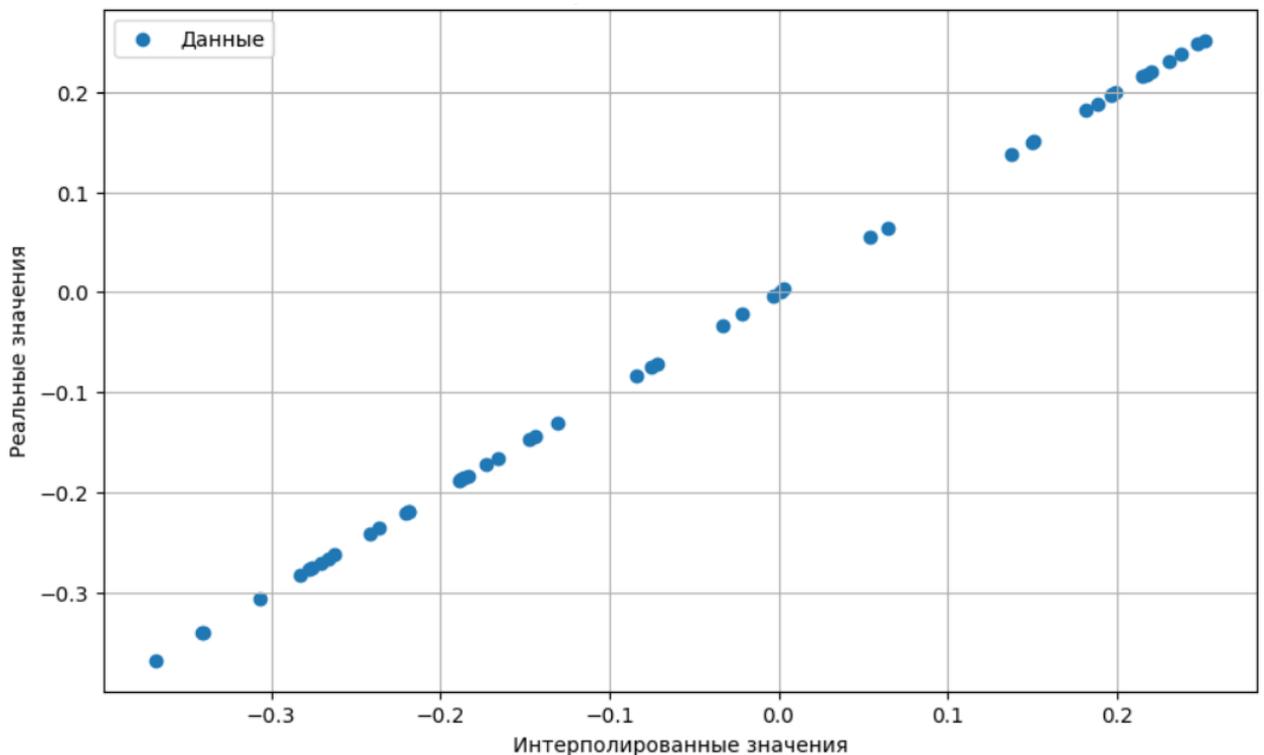


Рис. 21. Кросс – плот прогнозных и реальных значений.

Также приведена таблица метрик:

Метрика	Значение
MAE	0.7554
RMSE	0.8879
MAPE	1.332%
L2_norm	0.6221

Таблица 6. Метрики качества модели.

Где *MAE* (Mean Absolute Error), *MAPE* (Mean Absolute Percentage Error), *RSME* (Root Mean Square Error), *L2_norm* вычисляются аналогично формулам (4), (5), (9), (10) соответственно.

СРАВНЕНИЕ РЕЗУЛЬТАТОВ

Для более детального сравнения результатов приведем две таблицы двух методов:

	MAE	MAPE	R2
Метод 1 (Фурье)	1.2806	13.121%	0.8696
Метод 2 (Нейросеть)	1.5307	11.690%	0.8481

Таблица 7. Сравнение метрик качества моделей двух методов.

Из таблицы 7 по значениям метрик видно, что метод прогнозирования значений каротажа с помощью нейронной сети точнее, чем метод интерполяции каротажа рядом Фурье.

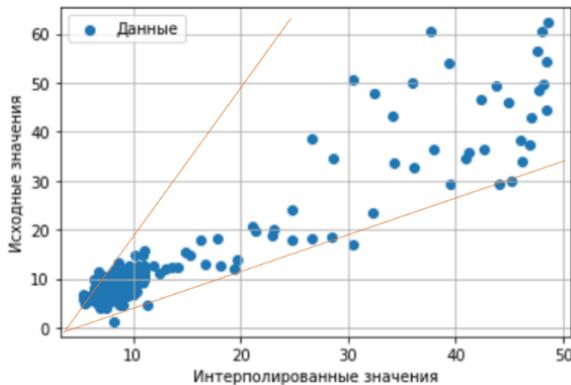


Рис. 22. Кросс – плот метода Фурье.

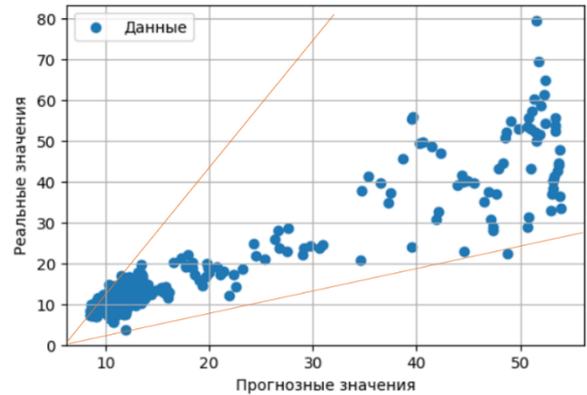


Рис. 23. Кросс – плот метода нейросетью.

Из рисунков 22 и 23 следует, что разброс значений, полученных путем прогнозирования нейросетью меньше, чем путем интерполяции рядом Фурье. Разброс примерно составляет 45 градусов, что свидетельствует о линейной зависимости между реальными и прогнозными значениями, точки плотно расположены вдоль линии тренда, что указывает на высокую корреляцию между переменными, из этого можно сделать вывод, схожести значений между собой.

Теперь сравним два метода пространственной интерполяции, для этого создадим таблицу:

	MAE	MAPE	RSME	L2_norm
Метод 1 (Фурье)	2.4094	16.238%	2.9749	20.8245
Метод 2 (Нейросеть)	0.7554	1.332%	0.8879	0.9221

Таблица 8. Сравнение метрики качества моделей двух методов.

Из таблицы 8 по значениям метрик видно, что метод пространственной интерполяции нейросетью с помощью нейронной сети наиболее точен метода интерполяции по пространству каротажа рядом Фурье.

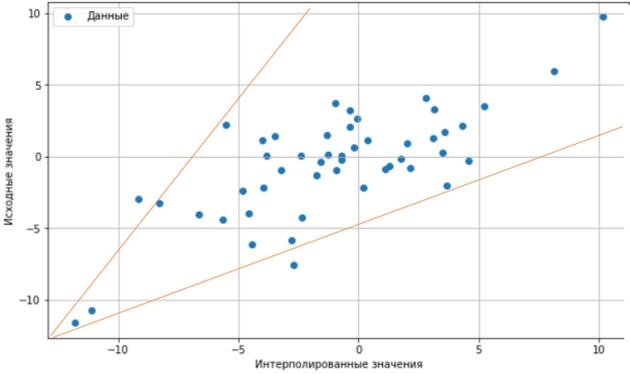


Рис. 24. Кросс – плот пространственной Интерполяции рядом Фурье.

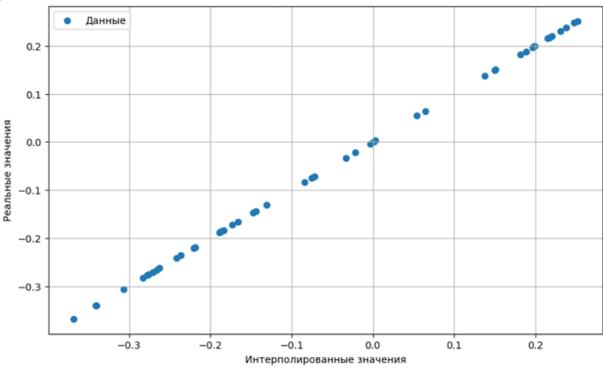


Рис. 25. Кросс – плот пространственной интерполяции нейросетью.

По рисунку 25 видно, что реальные и прогнозные коэффициенты совпадают, так как на кросс – плоте они образовали прямую линию. Что не сказать о рисунке 24, на нем значения немного отличаются друг от друга.

Исходя из полученных результатов, можно сделать вывод о том, что интерполяция по пространству нейронной сетью выдает наиболее точные значения, что свидетельствует о высокой сходимости метода.

ЗАКЛЮЧЕНИЕ

В ходе данной работы мною был проведен литературный обзор по данной теме, предполагаемой к использованию в данной работе, и выполнены постановки задач. Была проведена обработка .las файлов в Python, построены график гамма – каротажа, иллюстрации интерполяции каротажа рядом Фурье, прогнозирования значений каротажа нейронной сетью и пространственной интерполяции двух методов. Реализован существующий метод построения кубов геофизических атрибутов, в котором были получены коэффициенты гамма – каротажа на основе преобразования Фурье, и дальнейшая интерполяция этих коэффициентов по пространству. Также был разработан метод построения кубов гамма – каротажа прогнозированием нейронной сетью с дальнейшей пространственной интерполяцией полученных весовых коэффициентов. Были построены кросс – плоты, вычислены метрики для каждого метода и сделан вывод о том, что построение кубов геофизических атрибутов нейронными сетями, наиболее точен, чем метод, использующий преобразование Фурье.

Нейросетевые методы в построении кубов геофизических атрибутов, обеспечивают высокую точность, автоматизацию и возможность работы со сложными многомерными данными. Даже несмотря на существующие проблемы, такие как необходимость больших наборов данных и сложность настройки модели.

Нейронные сети продолжают развиваться и находить все большее применение в различных областях науки и техники, открывая новые возможности для автоматизации и анализа данных.

В дальнейшем мною планируется расширить изучение данной темы, рассмотреть методы прогнозирования нейронными сетями различных архитектур и видов. Также рассмотреть разные виды каротажей для более детального анализа кубов. И предложить наиболее точный нейросетевой метод построения кубов геофизических атрибутов.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Аронов В.И. «Методы построения карт геолого-геофизических признаков и геометризация залежей нефти и газа на ЭВМ», 1990.
2. Бахвалов, Н.С. Численные методы /Н.С.Бахвалов. – М.: Наука, 1973.
3. Кирсанов, А. В. «Нейронные сети в геофизике», 2017.
4. Косков В.Н., Косков Б.В. «Геофизические исследования скважин и интерпретация данных ГИС», 2007.
5. Нургалиев Д.К., Косарев В.Е., Косарева Л.Р., Насыртдинов Б.М. «Стандарт хранения данных каротажа LAS (версии 1.2 и 2.0). Учебное пособие», 2012.
6. Петренко В. А., Федоров С. П. «Гибридные модели глубокого обучения для анализа сейсмических данных», 2019.
7. Иванов, В. П., Смирнов, В. В. (2019). Применение методов машинного обучения для интерпретации геофизических данных. *Геология и разведка*, 60(4), 45-53.
8. Малышев А. А. (2018). Машинное обучение и нейронные сети в геофизических исследованиях. *Геофизика*, (5), 33-44.
9. Подольский А.К. (2016). Применение методов искусственного интеллекта в нефтегазовой промышленности. *Современная наука №3*, 33-36.
10. Тихонов П. А. (2020). Применение сверточных нейронных сетей для обнаружения геофизических аномалий. *Геология нефти и газа*, 45(4), 101-113.
11. Aggarwal Charu С. «Neural networks and deep learning», 2020.
12. Goodfellow, I., Bengio, Y., & Courville, A. « Deep Learning. MIT Press », 2016.
13. Haykin Simon. «Neural networks. A comprehensive foundation. Second edition», 2006.

14. Mohamed Sidahmed, Luigi Saputelli, Xian-Huan Wen and etc. «SPE Technical Report Data Analytics in Reservoir Engineering», 2019.
15. Alfeld. P. (1984). A trivariate Clough-Tocher scheme for tetrahedral data. *Computer Aided Geometric Design*, 1, 169.
16. Chen Y., Liu Q. (2018). Application of deep learning methods to oil and gas exploration. *Journal of Petroleum Science and Engineering*, 167, 1-8.
17. Farin. G. (1986). Triangular Bernstein-Bezier patches. *Computer Aided Geometric Design*, 3, 83-127.
18. LeCun Y., Bengio Y., Hinton G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
19. Wang S., Guo J. (2019). Hybrid deep learning model for well log data interpretation and reservoir characterization. *Petroleum Exploration and Development*, 46(2), 271-281.