

МОСКОВСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
имени М.В. ЛОМОНОСОВА
ГЕОЛОГИЧЕСКИЙ ФАКУЛЬТЕТ

На правах рукописи

Шклярук Алексей Дмитриевич

**Применение нейронных сетей при анализе аномальных
гравитационных и магнитных полей**

1.6.9. Геофизика

ДИССЕРТАЦИЯ

на соискание ученой степени
кандидата технических наук

Научный руководитель:
кандидат технических наук
Кузнецов Кирилл Михайлович

Москва – 2026

Введение.....	5
Глава 1. Основы теории нейронных сетей.....	11
1.1. История развития нейронных сетей	11
1.2. Основные понятия и архитектура нейронных сетей	12
1.3. Типы нейронных сетей	15
1.3.1. Нейронные сети прямого распространения (перцептрон)	16
1.3.2. Сети радиально-базисных функций	16
1.3.3. Сети обратного распространения (рекуррентные нейронные сети)	18
1.3.4. Сверточные нейронные сети	18
1.4. Обучение нейронных сетей	20
1.5. Выводы по Главе 1	24
Глава 2. Применение нейронных сетей в геофизике	26
2.1. Применение нейронных сетей в сейсморазведке, электроразведке и ГИС.....	26
2.2. Применение нейронных сетей в гравиразведке и магниторазведке	29
2.2.1. Применение нейронных сетей для решения обратных задач гравиразведки и магниторазведки.....	30
2.2.2. Применение нейронных сетей для выделения морфологических особенностей гравитационного и магнитного полей.....	36
2.2.3. Применение нейронных сетей при обработке аэрогравиметрических данных	40
2.2.4. Построение моделей гравитационного поля Земли с помощью нейронных сетей	40
2.2.5. Применение нейронных сетей при восстановлении морфологии структурных границ по гравитационному и магнитному полям	42
2.2.6. Методологические аспекты подготовки геолого-геофизических данных для обучения нейронных сетей.....	43
2.2.7. Заключение о применимости нейронных сетей в гравиразведке и магниторазведке .	44
2.3. Выводы по Главе 2	45
Глава 3. Выделение изометричных аномалий в гравитационных и магнитных полях на основе сверточных нейронных сетей.....	47
3.1. Методика создания синтетической обучающей выборки для выделения изометричных аномалий в аномальном гравитационном поле Луны	49
3.2. Подготовка данных аномального гравитационного поля Луны для применения обученной СНС.....	52
3.3. Экспериментальное исследование и оптимизация архитектуры СНС	53

3.3.1. Сравнительный анализ архитектур U-Net	54
3.3.2. Сравнительный анализ предобученных энкодеров	57
3.3.3. Исследование влияния объема обучающей выборки	59
3.3.4. Выбор финальной архитектуры и обоснование	62
3.3.5. Подбор гиперпараметров для обучения СНС.....	65
3.3.6. Сравнение методов компьютерного зрения и СНС для локализации масконов Луны	65
3.4. Локализация масконов Луны с использованием СНС и оценка их параметров	67
3.5. Выводы по Главе 3	73
Глава 4. Выделение осей линейных аномалий в гравитационных и магнитных полях на основе сверточных нейронных сетей.....	75
4.1. Методика создания синтетической обучающей выборки для выделения линейных аномалий в магнитном поле	75
4.2. Создание модели СНС и её апробация на модельном примере	78
4.3. Анализ устойчивости к вариациям ширины аномалий	80
4.4. Апробация обученной СНС на примере поля участка Баренцева моря	81
4.4.1 Сравнение с алгоритмом автоматического трассирования осей аномалий в КОСКАД 3D	84
4.5. Комплексный анализ изометричных и линейных аномалий на данных Баренцева моря..	85
4.6. Выводы по Главе 4	89
Глава 5. Восстановления структурных границ по геофизическим данным на основе нейронных сетей.....	91
5.1. Сравнение методов машинного обучения для оценки возможности восстановления поверхности горизонтов на модельном примере	93
5.2. Сравнение различных архитектур нейронных сетей для восстановления поверхности горизонтов в межпрофильном пространстве на модельном примере.....	95
5.3. Применение нейронных сетей в качестве метода для восстановления нескольких плотностных границ на реальных данных.....	106
5.3.1. Валидация на полных данных и экстраполяция за границы обучения.....	110
5.3.2. Интерполяция данных внутри обучающей выборки	114
5.3.3. Экстраполяция данных за границы обучающей выборки.....	115
5.3.4. Интерполяция данных при различной степени разрежения	117
5.4. Выводы по Главе 5	120
Заключение	122

Список терминов	124
Список литературы	129

Введение

Изучение строения Земли сохраняет свою актуальность как для поиска и добычи полезных ископаемых, решения инженерных задач, так и для различных фундаментальных исследований. При этом важность исследований распространяется не только на Землю, но и на близкие космические объекты, такие как Луна, Марс или Венера. Наиболее эффективным инструментом для таких исследований служит комплекс геолого-геофизических методов. В частности, при изучении глубинного строения, особенно на региональном этапе, ключевую роль играют методы потенциальных полей – гравиразведка и магниторазведка.

Диссертационное исследование посвящено анализу, разработке и применению алгоритмов на основе искусственных нейронных сетей для решения различных задач интерпретации аномальных гравитационных и магнитных полей.

Актуальность исследований

Современные методы интерпретации аномальных гравитационных и магнитных полей сталкиваются с рядом принципиальных ограничений, включая неоднозначность обратных задач, зависимость от априорных геологических моделей и высокую вычислительную сложность при обработке больших объемов данных. Развитие математических методов анализа и интерпретации данных грави- и магниторазведки направлено на преодоление этих ограничений. В этой связи активное применение технологий нейронных сетей открывает новые перспективы за счет возможности описывать сложные нелинейные зависимости в данных без явного задания их аналитических представлений [LeCun et al., 2015]. Важным преимуществом является адаптивность: нейронные сети могут обучаться на синтетических данных, моделирующих различные геологические ситуации, с последующей апробацией на реальных наблюдениях.

Особую актуальность нейронные сети приобретают в контексте задач автоматизации интерпретации [Bergen et al., 2019]. Традиционные подходы требуют значительных временных затрат и привлечения экспертов на всех этапах геологоразведочных работ. В отличие от них, обученные нейронные сети способны обеспечивать оперативный анализ данных, сокращая время, что особо важно для задач разведки и мониторинга, особенно в условиях изменяющегося объема априорной информации в процессе доразведки.

Значимость исследований подтверждается широким спектром приложений – от инженерных задач до изучения глубинного строения Земли и иных космических тел. В условиях экспоненциального роста объемов геофизических данных и ужесточения требований к точности прогнозов, развитие методов, основанных на нейронных сетях, представляется стратегически важным направлением, способным сократить сроки и затраты на геологоразведочные работы при повышении их достоверности.

Степень разработанности

Вопросы интерпретации гравитационных и магнитных полей активно изучаются в геофизике уже более ста лет. Традиционные методы, включая трансформации полей, их корреляционный и факторный анализ, аппроксимационные подходы, хорошо разработаны и широко применяются на практике [Гравиразведка..., 1990; Магниторазведка..., 1990], что подтверждается работами таких авторов, как Корбунов А.И., Страхов В.Н., Романюк Т.В., Никитин А.А., Старостенко В.И., Петров А.В., Мелихов В.Р., Булычев А.А., Тихоцкий С.А., Долгаль А.С., Мартышко П.С. и др. Однако их эффективность ограничена сложностью выделения целевых аномалий на фоне шумов и необходимостью значительных временных затрат на экспертный анализ данных. В последние годы активно развиваются подходы, основанные на искусственном интеллекте, включая машинное обучение и нейронные сети. [Naprstek, Smith, 2022; Zhou et al., 2024; Колмаков, 2023].

Несмотря на высокий потенциал для автоматизации процессов обработки и интерпретации, их применение в геофизике остается недостаточно изученным. Стоит отметить, что методы искусственного интеллекта в геофизике получили наибольшее развитие в анализе данных сейсморазведки, а в области потенциальных полей, несмотря на значительный прогресс, сохраняется потребность в разработке новых подходов, сочетающих традиционные методы с современными технологиями машинного обучения. В сейсморазведке нейронные сети успешно применяются для автоматической идентификации отражающих горизонтов, классификации фаций, выделения разрывных нарушений и иных задачах [Mosser, Naeini, 2021; Yang, Sun, 2020], в геофизических исследованиях скважин – для интерпретации каротажных данных и оценки фильтрационно-емкостных свойств [Rohit et al., 2024]. В отличие от этих направлений, применение искусственного интеллекта в анализе потенциальных полей развито значительно хуже, хотя отдельные работы демонстрируют его перспективность для решения таких задач, как построение структурных границ [Колмаков, 2023], решение обратных задач [Bai et al., 2024], выделения морфологических особенностей потенциальных полей [Naprstek, Smith, 2022] и др. Более подробный анализ современных методов интерпретации представлен в Главе 2 диссертационной работы.

Объект исследования

Объектом диссертационного исследования выступают аномальные гравитационные и магнитные поля, а также методы их интерпретации с применением современных методов машинного обучения, в частности нейронных сетей. Основное внимание сосредоточено на разработке методов на основе нейронных сетей для решения двух классов задач: реконструкция границ горизонтов (структурных, стратиграфических и др.) по комплексу геофизических данных и выделение линейных и изометричных аномалий в гравитационных и магнитных полях.

Объект исследования охватывает как теоретические аспекты анализа гравитационных и магнитных полей, так и практические задачи их интерпретации с применением нейронных сетей.

Цели и задачи

Основной целью диссертационного исследования является разработка новых методов на основе нейронных сетей для решения актуальных задач интерпретации аномальных гравитационных и магнитных полей, направленных на повышение эффективности геолого-геофизических исследований.

Для достижения поставленной цели в работе решены следующие научные задачи:

- Разработка методов с применением нейронных сетей для выделения линейных структур в аномальных гравитационных и магнитных полях;
- Разработка методов с применением нейронных сетей для выделения изометричных структур в аномальных гравитационных и магнитных полях;
- Разработка методов с применением нейронных сетей для реконструкции границ горизонтов (структурных, стратиграфических и др.) с использованием априорных геофизических данных.

Новизна исследования

Новизна исследования заключается в разработке и применении методов на основе нейронных сетей для решения ряда актуальных задач интерпретации аномальных гравитационных и магнитных полей. Новые, с применением нейронных сетей, подходы позволяют автоматизировать процесс составления схем аномалий, повысить точность интерпретации данных и сократить временные затраты на анализ. В частности, в работе предлагаются:

- Методика генерации синтетических обучающих выборок для сверточных нейронных сетей;
- Методы выделения линейных и изометричных структур в аномальных полях, основанные на возможностях нейронных сетей выявлять скрытые закономерности;
- Внедрение новых подходов машинного обучения в существующие методики интерпретации потенциальных полей, расширяющих их функциональные возможности;
- Новый подход к реконструкции структурных поверхностей с использованием априорных геофизических данных.

Теоретическая и практическая значимость

Теоретическая значимость работы заключается в развитии методологии интерпретации гравитационных и магнитных полей за счет внедрения методов искусственного интеллекта.

Разработанные методы позволяют формализовать процесс качественного анализа данных, а также повысить скорость и информативность результатов интерпретации.

Практическая значимость исследования связана с возможностью применения разработанных методов в различных областях геофизики, включая:

1. поиск и разведку полезных ископаемых;
2. исследование глубинного строения Земли и других космических объектов, таких как Луна, Марс и др.;
3. оптимизацию процессов обработки и интерпретации данных, что позволяет снизить затраты на геолого-геофизические исследования.

Методология и методы исследования

В рамках диссертационного исследования все разработанные методы реализованы в виде программ на языке Python с использованием современных библиотек для научных вычислений и глубокого обучения. Основой вычислительной платформы стали TensorFlow/Keras для построения и обучения нейронных сетей, Keras-unet-collection для реализации специализированных архитектур сверточных нейронных сетей (СНС), а также стандартные научные библиотеки NumPy/SciPy для численных расчетов и работы с табличными данными. Визуализация результатов осуществлялась с использованием библиотеки Matplotlib и специализированного ПО.

Ключевым достижением исследования стала разработка и программная реализация трех оригинальных методов. Первый метод основан на сверточных сетях архитектуры U-Net и позволяет автоматически выделять границы изометричных аномалий [Шклярук, Кузнецов, 2025б]. Второй метод также основан на сверточных сетях архитектуры U-Net и позволяет автоматически выделять линейные аномалии потенциальных полей [Шклярук, Кузнецов, 2024б]. Третий – метод реконструкции структурных поверхностей с использованием априорных геофизических данных на основе многослойной нейронной сети типа перцептрон [Шклярук, Кузнецов, 2024а].

Защищаемые положения

1. Методика создания репрезентативных синтетических выборок, основанная на расчете эффектов от тел простой геометрической формы с добавлением искусственной помехи, позволяет эффективно обучать нейронные сети для сегментации аномальных гравитационных и магнитных полей.
2. Применение сверточных нейронных сетей эффективно решает задачу выделения линейных и изометричных аномалий магнитных и гравитационных полей в сложных геолого-геофизических условиях.

3. Разработанный метод на основе нейронных сетей, обученных на эталонных участках, эффективно решает задачу восстановления морфологии границ разреза по комплексу геофизических данных.

Степень достоверности

Достоверность результатов исследования подтверждается использованием современного комплекса анализа данных, включая машинное обучение и нейронные сети, а также корректным применением математических моделей для обработки гравитационных и магнитных полей. Результаты работы верифицированы на геофизических данных, полученных в ходе полевых и камеральных гравиразведочных и магниторазведочных исследований. Проведено сравнение разработанных методов с традиционными методами интерпретации, показавшее их высокую сходимость.

Апробация результатов

Результаты настоящей работы опубликованы в 3 статьях, входящих в список RSCI, а также неоднократно докладывались на научных конференциях, совещаниях и семинарах:

- European Geosciences Union General Assembly – 2021 г.;
- 9, 12 и 13-я Международная научно-практическая конференция «Морские исследования и образование: MARESEDU» – 2020, 2023, 2024 г.;
- 27-я Международная научная конференция студентов, аспирантов и молодых ученых «Ломоносов 2020» – 2020 г.;
- 10-я Международная научно-практическая конференция «Морские технологии» – 2021 г.;
- Ломоносовские чтения. Секция геология. Подсекция геофизика – 2024 г.;
- 51 сессия международного семинара им. Д.Г. Успенского – В.Н. Стахова «Вопросы теории и практики геологической интерпретации гравитационных, магнитных и электрических полей» – 2025 г.;
- 4 и 6-ой Гравиметрический и магнитометрический семинар памяти профессора В.Р. Мелихова – 2020, 2022 г.

По результатам исследования получены 3 свидетельства о государственной регистрации программ для ЭВМ [Шклярчук, Кузнецов, 2024а; Шклярчук, Кузнецов, 2024б; Шклярчук, Кузнецов, 2025б].

Публикации

Основные идеи и положения диссертации опубликованы в 6 научных работах автора, из них 3 статьи – в рецензируемых научных изданиях, рекомендованных для защиты в диссертационном совете МГУ по специальности и отрасли наук.

Личный вклад

Автором лично выполнен весь цикл диссертационного исследования, начиная от постановки задач и разработки теоретических основ их решения, заканчивая программной реализацией предложенных подходов с проведением вычислительных экспериментов и анализом полученных результатов. Проведено конструирование архитектур нейронных сетей и их обучение для выделения линейных и изометричных аномалий в гравитационных и магнитных полях и для восстановления структурных поверхностей по комплексу геофизических данных. Автором разработана и реализована методика создания синтетических обучающих выборок для компенсации малого объема реальных размеченных материалов, а также осуществлен поиск, сбор и обработка геофизических данных для апробации предлагаемых подходов. Проведено полномасштабное тестирование разработанных методов, включая сравнительный анализ с традиционными методами машинного обучения и алгоритмами компьютерного зрения, и выполнена верификация результатов на модельных и реальных примерах.

Автор самостоятельно и вместе с соавторами участвовал в подготовке публикаций по теме проведенного диссертационного исследования. В них вклад автора является определяющим – автор принимал непосредственное участие в постановке научных задач, проведении численных экспериментов, разработке методик, интерпретации результатов, формулировке выводов, а также в подготовке непосредственно текстов статей.

Поддержка работы

Исследование, описанное в Главе 4 диссертации, выполнено в рамках использования морского продольного градиентометра «MagiMag 300m», приобретенного по программе развития Московского университета (Соглашение № 195 от 15 сентября 2023 г.).

Глава 1. Основы теории нейронных сетей

1.1. История развития нейронных сетей

Термин «нейронная сеть» появился в середине XX века. В 1943 году американские ученые У. Маккалок и У. Питтс в своей статье сформулировали понятие нейронной сети и представили ее модель, основанную на теории деятельности головного мозга, на электрических схемах [McCulloch, Pitts, 1943]. Они показали, что данная электронная сеть может выполнять практически любые числовые или логические операции. В 1949 году ученый из Канады Д. Хебб предложил первый алгоритм обучения нейронной сети, который заключался в поиске и изменении синаптических связей между нейронами.

Американский ученый Ф. Розенблатт в 1958 году изобрел нейронную сеть – однослойный перцептрон и в 1960 году реализовал его в виде электронной машины Марк-1 – первого в мире нейрокомпьютера [Rosenblatt, 1958].

После данного периода интерес к исследованию нейронных сетей угас из-за публикации в 1969 г. ученого из США М. Минского, в которой было показано, что однослойные нейронные сети не могут решать некоторые довольно простые задачи. Кроме того, вычислительные мощности компьютеров того времени были недостаточны для обработки огромного объема вычислений, требуемого для обучения больших нейронных сетей [Горбачевская, Краснов, 2015].

В 1974 году, опираясь на более ранние разработки Т. Кохонена, С. Гроссберга и Дж. Андерсона, исследователи П. Вербос и А. Галушкин независимо друг от друга предложили подход к обучению многослойной нейронной сети, основанный на алгоритме обратного распространения ошибки. В 1975 году ученый из Японии К. Фукусима разработал первую полноценную многослойную нейронную сеть, предназначенную для распознавания образов. Т. Кохонен в 1982 году изобрел первую нейронную сеть, обучающуюся без учителя [Горбачевская, Краснов, 2015].

Начало XXI века стало периодом бурного развития нейронных сетей, что было связано с ростом вычислительных мощностей, появлением больших объемов данных (Big Data) и разработкой новых вычислительных алгоритмов. Одним из ключевых событий стало возрождение интереса к глубоким нейронным сетям (Deep Learning), которые благодаря своей многослойной архитектуре способны решать сложные задачи, такие как распознавание образов на изображениях, обработка естественного языка, анализ временных рядов и др.

В 2006 году Джеффри Хинтон и его коллеги предложили метод обучения глубоких сетей с использованием ограниченных машин Больцмана (Restricted Boltzmann Machines, RBM) [Hinton et al., 2006]. Это открыло новые возможности для обучения многослойных сетей, которые

ранее были недоступны из-за проблемы исчезающих градиентов (при обучении очень глубоких нейронных сетей градиенты становятся настолько малыми, что почти не влияют на обучение). В 2012 году команда Хинтона достигла значительного успеха в конкурсе ImageNet, где их сверточная нейронная сеть (СНС) AlexNet показала рекордную точность в задаче классификации изображений [Krizhevsky et al., 2012]. Это событие стало одним из поворотных моментов в истории глубокого обучения.

В 2010-х годах появились новые архитектуры нейронных сетей, которые значительно расширили их возможности. Некоторые из них:

- Сверточные нейронные сети (СНС): после успеха AlexNet были разработаны более сложные архитектуры, такие как VGGNet [Simonyan, Zisserman, 2015], GoogLeNet [Szegedy et al., 2015a] и ResNet [He et al., 2016]. ResNet, в частности, представил концепцию остаточных блоков, что позволило обучать сети с сотнями слоев.

- Рекуррентные нейронные сети (РНС): архитектуры LSTM (Long Short-Term Memory) [Hochreiter, Schmidhuber, 1997] и GRU (Gated Recurrent Units) [Cho et al., 2014] стали эффективным инструментом для обработки последовательностей данных, таких как текст и временные ряды.

- Генеративные состязательные сети (GAN): предложенные Иэном Гудфеллоу в 2014 году [Goodfellow et al., 2014], GAN произвели революцию в генерации данных, таких как изображения, музыка и текст.

В 2010-х годах появились мощные библиотеки для разработки нейронных сетей, такие как TensorFlow (Google, 2015) и PyTorch (Facebook, 2016). Эти фреймворки сделали глубокое обучение доступным для широкого круга исследователей и разработчиков, что способствовало быстрому распространению технологий.

1.2. Основные понятия и архитектура нейронных сетей

Нейронная сеть – это математическая модель, состоящая из множества взаимосвязанных элементов, называемых нейронами. Каждый нейрон принимает входные сигналы, обрабатывает их с помощью весовых коэффициентов путем умножения на них и передает результат через функцию активации (Рисунок 1). Основные компоненты нейронной сети включают:

- Входной слой – получает исходные данные (например, значения гравитационного или магнитного поля). Количество нейронов во входном слое соответствует количеству признаков в данных.

- Скрытые слои – выполняют преобразование данных. Каждый скрытый слой состоит из множества нейронов, которые обрабатывают информацию, поступающую от предыдущего слоя.

Глубина сети (количество скрытых слоев) определяет ее способность моделировать сложные зависимости.

- Выходной слой – формирует итоговый результат. Например, в задачах классификации выходной слой может содержать нейроны, соответствующие различным классам объектов.

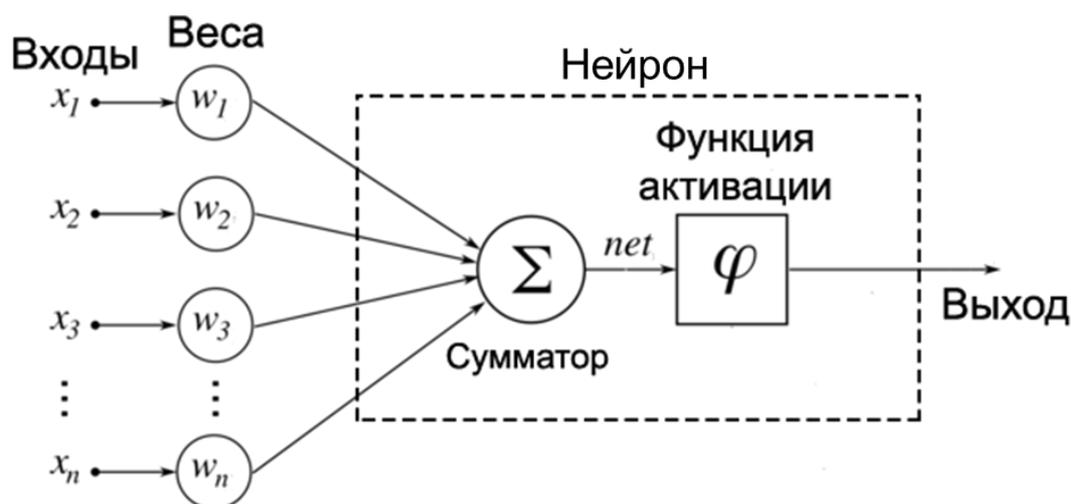


Рисунок 1 – Схема связи слоев нейронной сети

Нейрон – это нелинейный преобразователь, который принимает вектор входов x , вычисляет скалярное произведение с вектором весов w и применяет функцию активации для получения выхода [Bishop, 2006]. В случае, когда нейронная сеть состоит из большого количества нейронов, вводят термин слоя. Каждый нейрон одного слоя связан с нейроном другого слоя – полносвязная нейронная сеть. Сигнал перед тем, как пройти от одного нейрона в другой, поступает в сумматор и проходит через функцию активации (Рисунок 1).

Синапс – это связь между двумя нейронами. Каждая связь характеризуется определенным числом, называемым весом данной связи. Сигнал, прошедший через данную связь, умножается на это число [Хайкин, 2006].

Сумматор – суммирует все входные сигналы, умноженные на веса. Полученный результат передается в функцию активации.

Функция активации – это математическое преобразование, которое применяется к выходному сигналу, полученному из сумматора [Goodfellow et al., 2016].

На сегодняшний день существует множество моделей нейронных сетей и алгоритмов машинного обучения. В начале рассмотрим основные виды нейронных сетей.

Существуют однослойные и многослойные нейронные сети. *Слой* – это набор нейронов, несвязанных между собой. В однослойной нейронной сети сигнал от входного слоя сразу направляется на выходной слой, который не только преобразует сигнал, но и сразу же выдает

ответ. Как отмечено выше, нейроны в сетях связываются между слоями с помощью синапсов, обладающих определенным весом, полученным в ходе обучения нейронной сети (Рисунок 1). В многослойных нейронных сетях помимо выходного и входного слоев имеются промежуточные скрытые слои (количество данных слоев может быть неограниченно и выбирается исходя из решаемой задачи). Многослойные сети обладают большими возможностями чем однослойные, так как каждый промежуточный слой – это промежуточный этап, на котором осуществляется обработка и распределение информации.

Функции активации представляют собой ключевой компонент искусственных нейронных сетей, обеспечивающий их нелинейные свойства и способность к описанию сложных зависимостей. На структурном уровне функция активации определяет выходное значение нейрона на основе взвешенной суммы его входов. Математически это преобразование можно описать как нелинейное отображение, применяемое к результату скалярного произведения входного вектора и вектора весов с добавлением смещения.

Основная цель введения функции активации заключается в преодолении принципиальных ограничений линейных преобразований. Без нелинейных активационных функций многослойная нейронная сеть вырождалась бы в эквивалент однослойного перцептрона, теряя возможность аппроксимировать произвольные непрерывные функции. Это следует из теоремы о суперпозиции линейных операторов, согласно которой композиция линейных преобразований остается линейным преобразованием.

Практический выбор функции активации определяется спецификой решаемой задачи.

Сигмоидная функция (логистическая кривая) обеспечивает сжатие выхода в интервал $(0, 1)$, что интерпретируется как вероятность принадлежности к классу в задачах бинарной классификации (Рисунок 2А). Однако она малоэффективна в глубоких архитектурах. Сигмоида описывается формулой:

$$f(x) = \frac{1}{1+e^{-x}} \quad (1)$$

Гиперболический тангенс с диапазоном значений $(-1, 1)$ демонстрирует лучшие свойства градиента по сравнению с сигмоидой, что заключается в решении проблемы «затухающих градиентов»: его выход симметричен относительно нуля, что ускоряет сходимость модели. Данная функция традиционно применяется в рекуррентных сетях и задачах регрессии и описывается формулой (Рисунок 2Б):

$$f(x) = \frac{2}{1+e^{-2x}} - 1. \quad (2)$$

Функция активации ReLU и ее модификации (Leaky ReLU, Parametric ReLU и др.) широко применяются в нейронных сетях благодаря простоте и эффективности. ReLU пропускает положительные значения без изменений, а отрицательные преобразует в ноль. Это обеспечивает высокую скорость вычислений и устойчивое обучение без затухания градиентов [Nair, Hinton, 2010]. Линейный характер ReLU на положительных значениях дополнительно способствует стабильному обучению даже в глубоких сетях (Рисунок 2В).

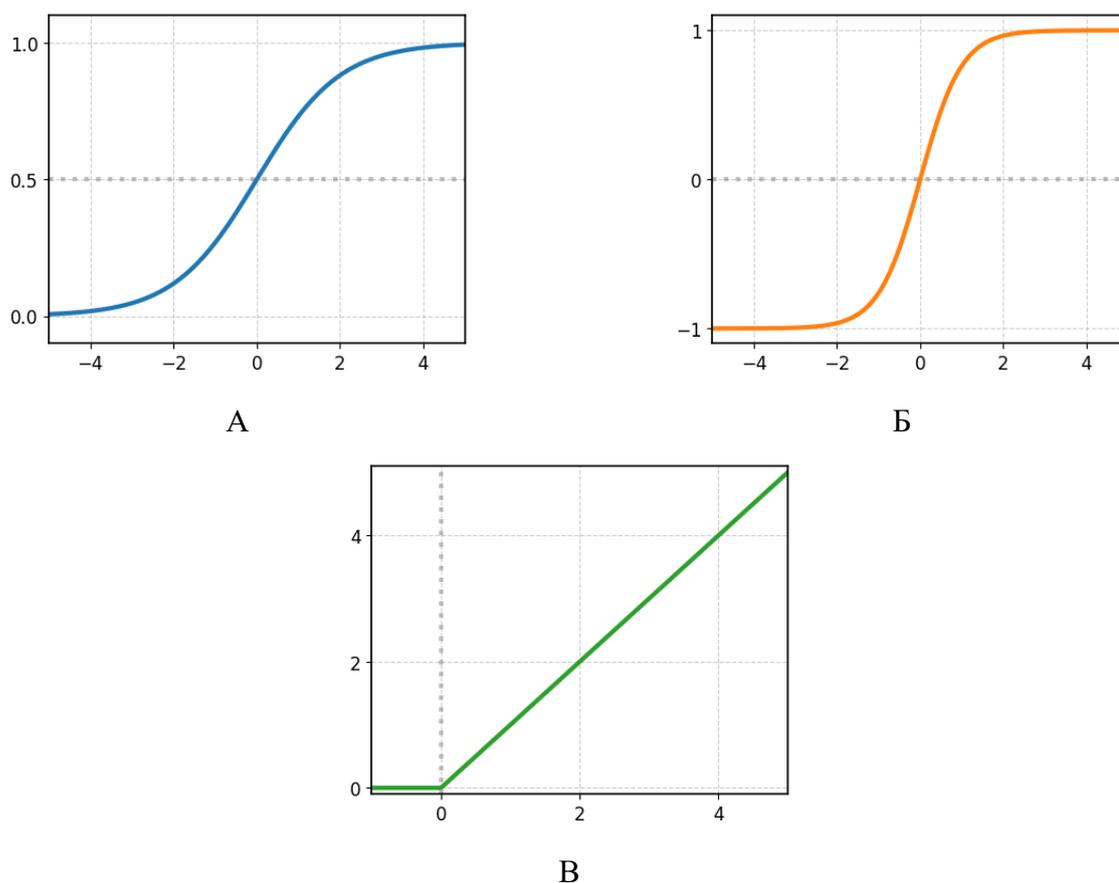


Рисунок 2 – Функции активации: А – сигмоида; Б – гиперболический тангенс; В – ReLU

1.3. Типы нейронных сетей

Нейронные сети можно классифицировать по направлению распространения информации между нейронами на четыре основных типа [Goodfellow et al., 2016]:

1. сети прямого распространения (перцептрон);
2. сети радиально-базисных функций;
3. сети обратного распространения (рекуррентные нейронные сети);
4. сверточные нейронные сети.

1.3.1. Нейронные сети прямого распространения (перцептрон)

Многослойные сети состоят из входных, скрытых и выходных слоев. Нейроны одного слоя не связаны между собой, а соседние слои полностью связаны, то есть каждый нейрон одного слоя соединяется синапсами с каждым нейроном последующего слоя (Рисунок 3) [Bishop, 2006].

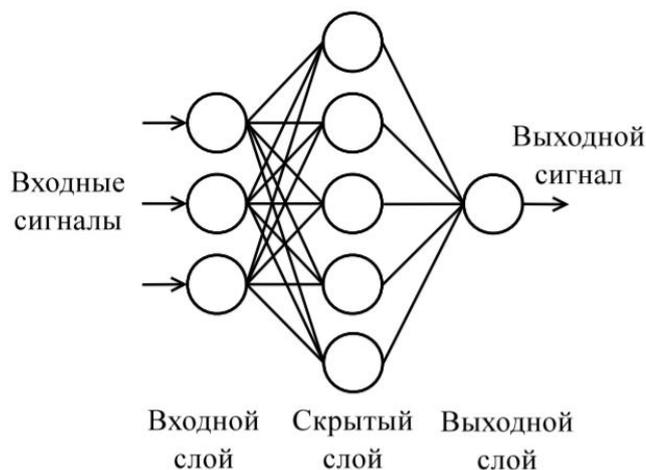


Рисунок 3 – Многослойная нейронная сеть прямого распространения с одним скрытым слоем
[Созыкин, 2017]

Ключевой особенностью таких сетей является их способность аппроксимировать сложные нелинейные зависимости между входными и выходными данными. Теоретически, при наличии достаточного количества нейронов в скрытых слоях, многослойный перцептрон может приблизить любую непрерывную функцию с произвольной точностью [Cybenko, 1989].

Архитектурные параметры сети включают:

- количество скрытых слоев;
- число нейронов в каждом слое;
- тип используемых функций активации;
- схему соединения между слоями.

Эти параметры определяют вычислительную мощность сети и должны подбираться в соответствии с решаемой задачей [Goodfellow et al., 2016].

1.3.2. Сети радиально-базисных функций

Сеть радиально-базисных функций также является нейронной сетью прямого распространения. Характерное свойство радиально-базисной функции заключается в том, что веса нейронов монотонно убывают или возрастают при удалении от начала координат или

расстояния от некоторой другой точки, называемой центром. Например, такая функция может описываться функцией Гаусса, убывающей от своего экстремального значения (Рисунок 4) [Горбаченко, Артюхина, 2007].

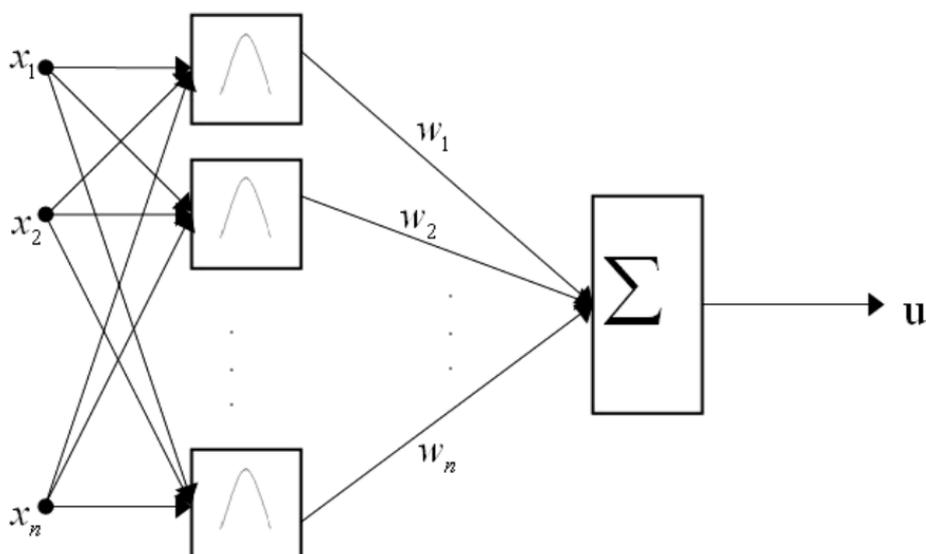


Рисунок 4 – Радиально-базисная нейронная сеть [Горбаченко, Артюхина, 2007]

Скрытый слой преобразует входной вектор X с использованием радиально-базисной функции – гауссиан, имеющий следующий вид для k -го нейрона:

$$\varphi_k(X) = \exp(-r_k^2/a_k^2), \quad (3)$$

где X – входной вектор; r_k – радиус, a_k – ширина окна,

$$r_k = \|X - C_k\|, \quad (4)$$

где C_k – вектор центра радиально-базисной функции, $\|x\|$ – норма [Бахвалов и др., 2008].

Выходной слой сети представляет линейный сумматор, а выход сети описывается выражением:

$$u = \sum_{k=1}^N w_k \varphi_k(X), \quad (5)$$

где w_k – вес, связывающий выходной нейрона с k -м нейроном скрытого слоя [Горбаченко, Артюхина, 2007].

1.3.3. Сети обратного распространения (рекуррентные нейронные сети)

Структура рекуррентной нейронной сети аналогична сети прямого распространения, однако в ней сигнал может распространяться как в прямом, так и в обратном направлении (Рисунок 5).

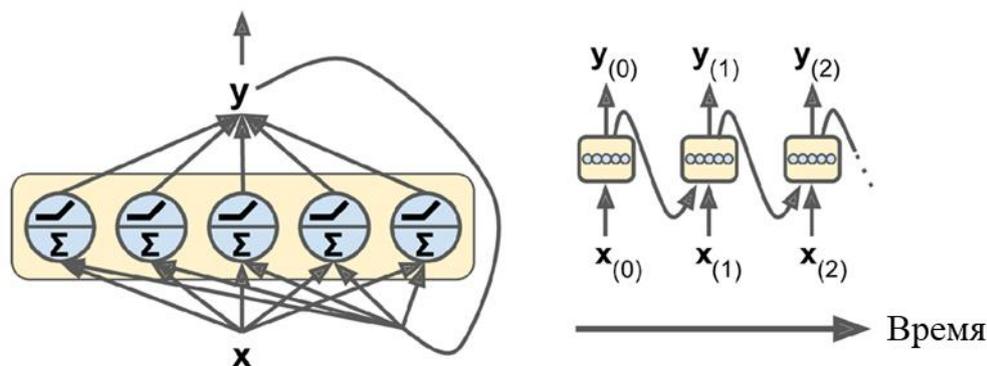


Рисунок 5 – Слой рекуррентных нейронов (слева), развернутый во времени (справа)
[Geron, 2019]

Значение на выходном нейроне определяется весовыми характеристиками синапсов и входными сигналами, а также дополняется предыдущими выходами, вернувшимися на вход. Этим нейронным сетям присуща функция кратковременной памяти, на основании чего сигналы восстанавливаются и дополняются во время их обработки. Обучение данной нейронной сети аналогично обучению сети прямого распространения, однако сигнал сначала проходит от входа к выходу, а затем применяется алгоритм обратного распространения ошибки.

1.3.4. Сверточные нейронные сети

Сверточная нейронная сеть (СНС) – это тип многослойного перцептрона (нейронной сети прямого распространения), часть слоев которой сконструирована таким образом, что связь между ними описывается дискретной сверткой [Venkatesan, Li, 2017; Хайкин, 2006]. На вход таких слоев подается числовая матрица, с которой сворачивается ядро, определяемое весами нейронов. На выходе формируется матрица числовых признаков, которая подается на вход следующего слоя (Рисунок 6).

Матрица, получаемая в результате свертки, имеет меньший размер, поскольку центр ядра преобразования не может быть совмещен с крайними элементами входной матрицы [Stankovic, Mandic, 2021]. Это видно из рисунка 6, где невозможно переместить ядро выше или левее. Если размерность выходной матрицы должна совпадать с размерностью входной, применяется метод *паддинг* – искусственное добавление нулевых значений по краям входной

матрицы. Если же требуется получить матрицы меньшего размера, то применяется метод *стридинг* – увеличение шага перемещения ядра свертки [Stankovic, Mandic, 2021]. Такие методы могут быть представлены отдельными слоями нейронной сети.

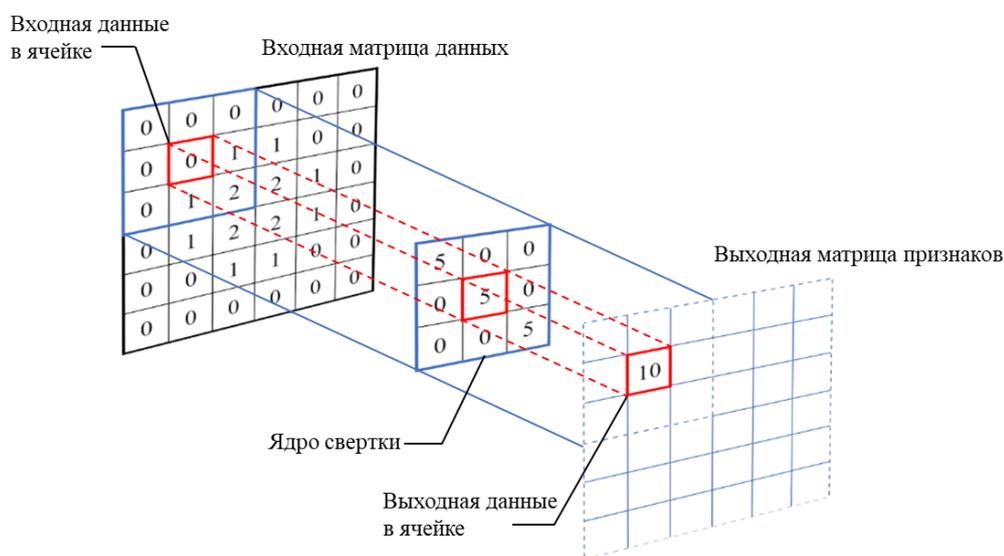


Рисунок 6 – Схема работы сверточного слоя нейронной сети

Также в сверточных нейронных сетях используются слои *объединения (пулинга)*, представляющие собой операцию сжатия матрицы путем усреднения или выбора максимального значения из группы соседних элементов (Рисунок 7А). Этот слой важен для извлечения доминирующих признаков. Объединение может быть основано на выборе максимального или среднего значения в блоке. Существует и обратная операция, увеличивающая размерность матрицы – *расширение (апсемплинг)* (Рисунок 7Б) [Stankovic, Mandic, 2021].

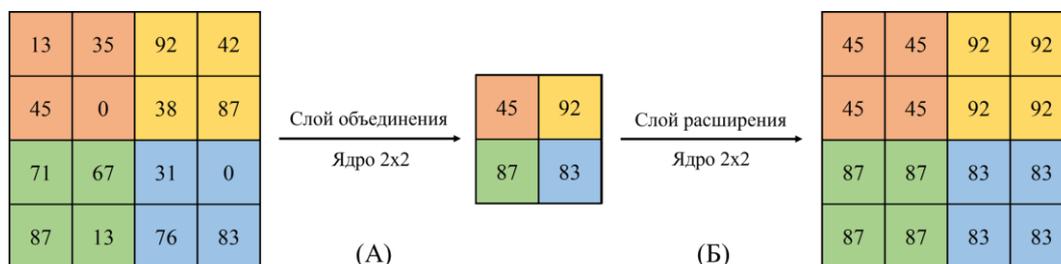


Рисунок 7 – Пример работы слоя объединения (А) и слоя расширения (Б)

1.4. Обучение нейронных сетей

Обучение нейронных сетей – это процесс настройки весов сети, направленный на минимизацию ошибки предсказания на обучающей выборке. Обучающая выборка – это набор размеченных данных (пар «вход-выход»), используемый для настройки параметров нейронной сети в процессе обучения. Процесс обучения включает несколько ключевых этапов: прямое распространение, вычисление функции потерь, обратное распространение ошибки и обновление весов. Рассмотрим каждый из этих этапов подробнее.

- Прямое распространение – это процесс, при котором входные данные проходят через все слои нейронной сети, начиная с входного слоя и заканчивая выходным. На каждом слое выполняются следующие операции:

1. Взвешенное суммирование: каждый нейрон вычисляет взвешенную сумму входных данных:

$$z = \sum_{i=1}^n w_i x_i + b, \quad (6)$$

где w_i – весовые коэффициенты, x_i – входные данные, b – смещение, z – взвешенная сумма входных данных.

2. Применение функции активации: результат взвешенного суммирования передается через функцию активации:

$$a = f(z), \quad (7)$$

где f – функция активации (например, ReLU, сигмоида, гиперболический тангенс и др.).

На выходе сети формируется предсказание, которое сравнивается с уже известными данными из обучающей выборки для вычисления ошибки [Goodfellow et al., 2016].

- Функция потерь позволяет оценить, насколько результаты, полученные нейронной сетью, отличаются от эталонных значений в обучающей выборке. Она необходима для оптимизации процесса обучения. Выбор функции потерь зависит от типа задачи. Например:

1. Для задач регрессии часто используется среднеквадратичная ошибка (MSE):

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2, \quad (8)$$

где y_i – реальное значение, \hat{y}_i – предсказанное значение, N – количество данных.

2. Для задач классификации, где необходимо разбить данные на фиксированные классы, применяется кросс-энтропия:

$$Cross - Entropy = - \sum_{i=1}^N y_i \log(\hat{y}_i), \quad (9)$$

где y_i – истинная метка класса, \hat{y}_i – предсказанная вероятность принадлежности к классу [Bishop, 2006].

• В отличие от функции потерь, метрики качества оценивают эффективность модели на основе ее предсказаний, но не используются непосредственно для обновления весов в процессе обучения. Метрики необходимы для оценки качества модели на этапах валидации и тестирования. Среди наиболее популярных метрик:

1. Accuracy (точность): доля правильных прогнозов модели среди всех сделанных прогнозов. Показывает, насколько часто модель выдает верный ответ. Наиболее эффективна на сбалансированных выборках [Hastie et al., 2009]:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}, \quad (10)$$

где TP (True Positive) – количество верно предсказанных положительных примеров, TN (True Negative) – количество верно предсказанных отрицательных примеров, FP (False Positive) – количество ложно положительных примеров (ошибка I рода), FN (False Negative) – количество ложно отрицательных примеров (ошибка II рода).

2. Precision (прецизионность): доля истинно положительных прогнозов среди всех случаев, которые модель отнесла к положительному классу. Показывает надежность положительного прогноза модели [Davis, Goadrich, 2006]. Высокая точность важна в задачах, где ложноположительные результаты приводят к значительным затратам, например, при автоматическом выделении перспективных объектов для постановки дорогостоящих детальных работ.

$$Precision = \frac{TP}{TP + FP} \quad (11)$$

где TP (True Positive) количество истинно положительных прогнозов, FP (False Positive) – количество ложноположительных прогнозов (ошибка I рода).

3. Recall (полнота): доля истинно положительных прогнозов среди всех реально положительных случаев. Показывает, какую долю объектов целевого класса модель смогла идентифицировать. Высокая полнота важна в задачах, где недопустим пропуск целевого объекта (например, в медицинской диагностике) [Davis, Goadrich, 2006].

$$Recall = \frac{TP}{TP + FN} \quad (12)$$

где TP (True Positive) – количество истинно положительных прогнозов, FN (False Negative) – количество ложно отрицательных прогнозов (ошибка II рода).

4. F1-Score (F-мера) – гармоническое среднее между метриками Precision и Recall. Данная метрика позволяет учесть баланс между прецизионностью и полнотой, что особенно полезно для несбалансированных выборок [Sokolova, Lapalme, 2009].

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} = \frac{2TP}{2TP + FP + FN} \quad (13)$$

где TP (True Positive) – количество истинно положительных прогнозов, FP (False Positive) – количество ложно положительных прогнозов (ошибка I рода), FN (False Negative) – количество ложно отрицательных прогнозов (ошибка II рода).

В задачах бинарной сегментации изображений в качестве метрик качества широко используются бинарная кросс-энтропия (Binary Cross-Entropy) и оценка пересечения над объединением (Intersection over Union) [Ronneberger et al., 2015].

Binary Cross-Entropy (BCE) – метрика, позволяющая оценить расхождение между предсказаниями модели и истинными значениями в задачах бинарной классификации. Она используется, когда на выходе модели ожидается вероятность принадлежности к одному из двух классов (например, "маскон есть" или "маскона нет") [Chollet, 2017].

Формула для расчета бинарной кросс-энтропии выглядит следующим образом [Chollet, 2017]:

$$BCE = -\frac{1}{N} \sum_{i=1}^N [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)], \quad (14)$$

где N – количество элементов в выборке; y_i – истинное значение i -го элемента (0 или 1); p_i – предсказанная моделью вероятность принадлежности к классу 1 (значение от 0 до 1).

Intersection over Union (IoU) – это метрика качества, которая позволяет оценить степень пересечения между двумя областями: предсказанной моделью и истинной. Она часто используется для оценки качества в задачах семантической сегментации и детекции объектов и вычисляется по формуле [Rahman, Wang, 2016]:

$$IoU = \frac{\text{Пересечение (Intersection)}}{\text{Объединение (Union)}} = \frac{|A \cap B|}{|A \cup B|} \quad (15)$$

где A – предсказанная область; B – истинная область; $|A \cap B|$ – площадь пересечения; $|A \cup B|$ – площадь объединения.

- Обратное распространение ошибки – это алгоритм вычисления градиентов функции потерь для всех весов сети. Он включает следующие шаги:

1. Вычисление градиента на выходном слое: для каждого нейрона выходного слоя вычисляется производная функции потерь по его выходу.

2. Распространение градиента в скрытых слоях: градиенты вычисляются для каждого скрытого слоя, начиная с последнего и двигаясь к первому. Для каждого нейрона вычисляется производная функции потерь по его входам и весам.

3. Обновление градиентов: градиенты используются для корректировки весов и смещений [Rumelhart et al., 1986].

- После вычисления градиентов веса w_i и смещения b обновляются с использованием оптимизаторов – алгоритмов, которые определяют, как именно на основе градиентов производить обновление параметров. Наиболее распространенные методы оптимизации:

1. Стохастический градиентный спуск (SGD) – базовый алгоритм оптимизации, обновляющий веса нейронной сети на основе градиента функции потерь [Bottou, 2010].

2. Adam (Adaptive Moment Estimation) – адаптивно позволяет учесть амплитуду изменения весов на одной итерации обучения (скорость обучения), что ускоряет сходимость [Kingma, Ba, 2015].

3. RMSprop – этот метод позволяет изменять скорость обучения в зависимости от величины градиентов, что помогает избежать колебаний [Tieleman, Hinton, 2012].

Оптимизатор является одним из ключевых гиперпараметров – параметров, которые не подбираются в самом процессе обучения модели нейронной сети, но напрямую влияют на её производительность и процесс обучения. Правильный выбор гиперпараметров позволяет

достичь баланса между точностью работы модели и временем её обучения [Chollet, 2017]. К другим критически важным гиперпараметрам относятся:

1. Количество эпох определяет, сколько раз через модель пройдут наборы данных. Большое количество эпох может привести к переобучению, слишком малое – к недообучению.

2. Скорость обучения определяет амплитуду изменения весов на каждом шаге обучения. Слишком высокая скорость обучения может привести к тому, что модель в процессе обучения не сойдется в устойчивый локальный минимум функции потерь, а слишком низкая – замедлит процесс обучения, и заданного числа итераций (эпох) обучения не хватит для достижения наилучшего решения.

3. Размер пакета данных определяет количество данных, которые модель обрабатывает за один шаг обучения перед обновлением весов. Увеличение размера может ускорить обучение, но требует больше памяти.

Один полный проход по всем данным (все пакеты данных) называют эпохой. При обучении важно контролировать не только скорость сходимости, но и способность модели к обобщению – то есть её производительность на независимом тестовом наборе данных, который не использовался в процессе обучения. Даже при эффективной оптимизации нейронная сеть может столкнуться с проблемой переобучения – ситуацией, когда модель демонстрирует высокую точность на обучающих данных, но не применима к новым данным. Это происходит, когда сеть чрезмерно подстраивается под особенности обучающей выборки, включая шум и случайные артефакты, вместо выявления устойчивых зависимостей между входными геофизическими признаками и целевой переменной (например, глубиной горизонта). Переобучение особенно вероятно при недостаточном объеме данных или избыточной сложности нейронной сети (например, слишком большом числе слоев или весов). Для предотвращения переобучения используются следующие методы регуляризации:

1. Дропаут (Dropout) – во время обучения случайно отключается часть нейронов, что предотвращает зависимость модели от конкретных признаков [Srivastava et al., 2014].

2. L_1/L_2 -регуляризация – в функцию потерь добавляется штраф за большие значения весов. L_1 -регуляризация способствует разреженности весов, а L_2 – их уменьшению [Bishop, 2006].

3. Ранняя остановка (Early Stopping) – обучение прекращается, когда ошибка на валидационной выборке перестает уменьшаться [Prechelt, 1998].

1.5. Выводы по Главе 1

Анализ теоретических основ нейронных сетей позволяет сделать следующие выводы для их применения в интерпретации аномальных гравитационных и магнитных полей.

Современные нейронные сети, особенно глубокие архитектуры, благодаря развитию вычислительных мощностей и алгоритмов обучения, представляют эффективный инструмент для решения сложных нелинейных задач в том числе и для анализа геофизических данных. Их иерархическая структура и возможность аппроксимировать сложные зависимости с помощью нелинейных функций активации напрямую соответствуют потребностям выявления скрытых закономерностей в аномальных полях и их связи с источниками. Разнообразие архитектур позволяет выбирать оптимальные модели для конкретных задач: сверточные сети – для обработки карт аномальных гравитационных и магнитных полей, рекуррентные сети – для анализа временных последовательностей, а многослойные перцептроны – для регрессионных задач.

Критическое значение имеет корректная организация обучения, включая выбор функций потерь, оптимизаторов и метрик качества, а также обязательное применение методов регуляризации (Дропаут, L_1/L_2) для предотвращения переобучения на ограниченных геофизических данных.

Таким образом, нейронные сети предоставляют перспективный математический аппарат для автоматизации и повышения точности интерпретации аномальных геофизических полей, что составляет основную цель настоящего исследования.

Глава 2. Применение нейронных сетей в геофизике

Обработка и интерпретация геофизических данных связаны с решением сложных задач, многие из которых требуют анализа больших объемов информации, поиска неочевидных, нелинейных зависимостей и комплексирования данных различной размерности и природы. Аналитические методы зачастую ограничены в своем применении из-за зашумленности данных, неоднозначности решений обратных задач и субъективности интерпретации. Нейронные сети, впервые предложенные как концепция в 1943 году, развились в мощный инструмент машинного обучения, способный эффективно решать эти задачи [Горбачевская, Краснов, 2015]. Их ключевые преимущества заключаются в способности выявлять сложные связи в данных, устойчивости к шуму, высокой скорости работы после обучения и возможности автоматизации рутинных процессов.

2.1. Применение нейронных сетей в сейсморазведке, электроразведке и ГИС

На сегодняшний день использование нейронных сетей находит все большее применение в различных областях науки, в том числе в геологии и геофизике. Важно отметить, что сейчас это направление активно развивается главным образом для решения задач обработки и интерпретации данных сейсморазведки. Нейронные сети могут обеспечить быстрое и точное автоматическое решение, например, для:

1. литологической интерполяции между скважинами;
2. отслеживания положения горизонтов (Рисунок 8);
3. сегментации сейсмических разрезов (Рисунок 9);
4. выделения разрывных нарушений;
5. и др.

Этим задачам посвящены работы многих ученых, например, специалистов из Нидерландов [Silva et al., 2019], Канады [Peters et al., 2019], Великобритании [Mosser, Naeini, 2021], Китая [Zhang et al., 2024; Zhang et al., 2025; Yang, Sun, 2020; Wu et al., 2019] и др. Ученые из России в своих работах [Логинов и др., 2019; Егоров, Кубышта, 2020; Приезжев и др., 2022] рассматривают задачи детектирования первых вступлений и выделения разрывных нарушений. В связи с достаточно большими объемами данных сейсморазведки, нейронные сети позволяют сильно ускорить процесс обработки и интерпретации с необходимой точностью.

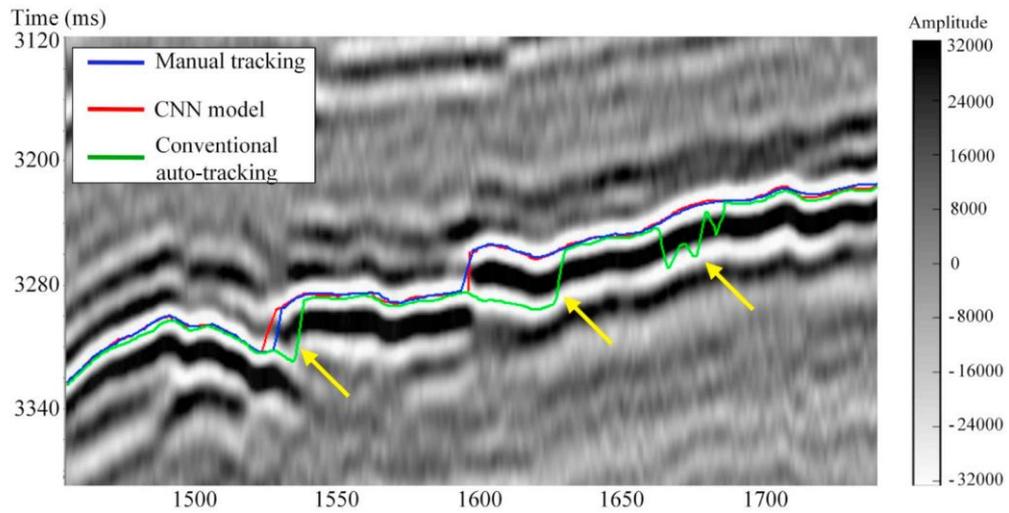


Рисунок 8 – Сравнение трех результатов пикирования границы. Синим – ручное пикирования; красным – пикирование с помощью сверточной нейронной сети; зеленым – автоматическое пикирование в специализированном программном обеспечении [Yang, Sun, 2020]

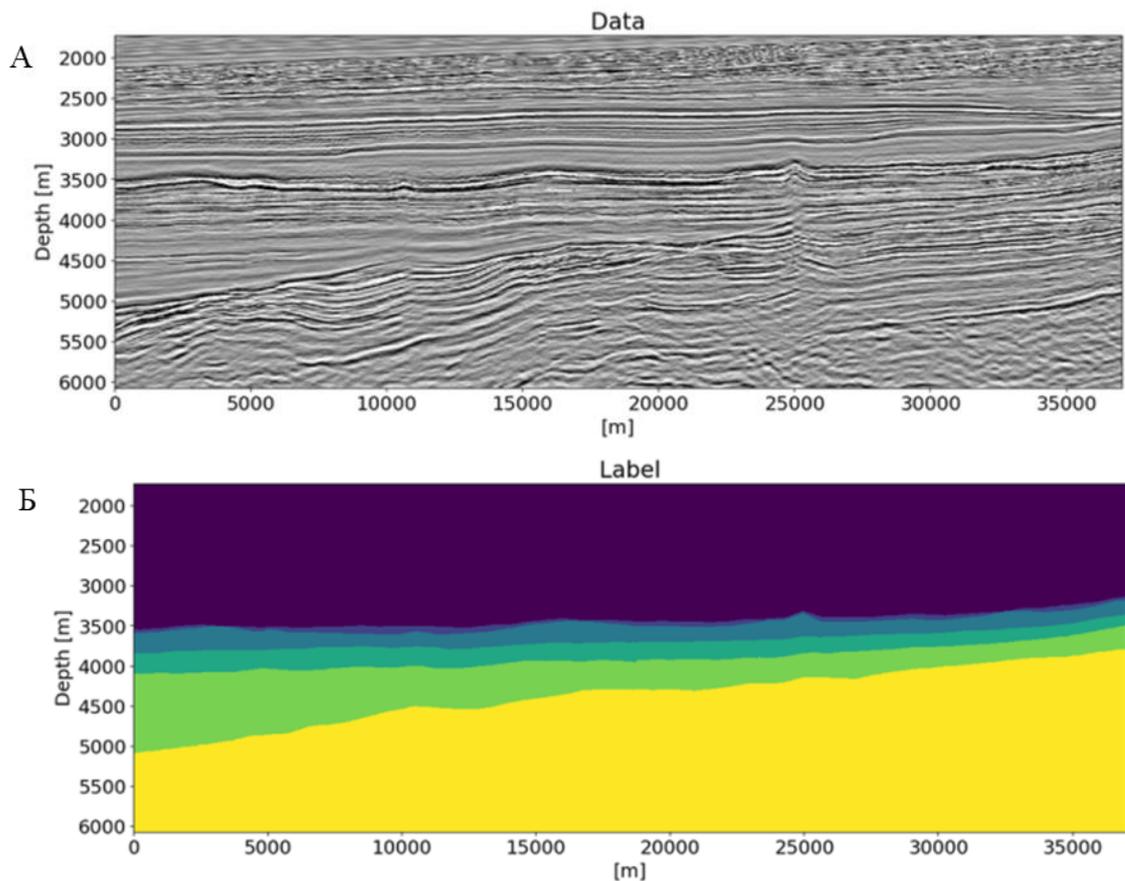


Рисунок 9 – Итог работы сверточной нейронной сети [Peters et al., 2019]:

А – Сейсмический разрез (входные данные); Б – Сегментированный, с помощью нейронной сети, сейсмический разрез

Поскольку применение нейронных сетей зачастую позволяет оценить зависимости между параметрами, которые не имеют четко выраженной физической и математической связи, то их возможно эффективно применять в комплексировании геолого-геофизических методов. Например, входным слоем нейронной сети могут являться данные комплекса измеряемых полей и/или их вторичных признаков, а результатом – интерпретируемый комплексный параметр. В процессе обучения сеть самостоятельно выявляет иерархию абстрактных признаков, которые формируются в промежуточных (скрытых) слоях и являются нелинейными комбинациями исходных данных. Выходной слой сети представляет комплексный параметр в виде коэффициента правдоподобия или в виде апостериорной вероятности, рассчитываемых по информативной совокупности признаков. Такие сети называют вероятностными [Никитин, Хмелевской, 2004].

Также нейронные сети используются для обеспечения количественной интерпретации данных ГИС. Так, например, для данных электрокаротажа, полученных на интервалах, сложенных маломощными контрастными по свойствам пластами. Нейронные сети сочетают в себе преимущества интерпретации данных на базе двумерной осесимметричной модели среды и быстродействие, что позволяет использовать их на этапе первичной обработки, повышая достоверность оперативной интерпретации [Леоненко и др., 2021].

Нейронные сети применяются при решении обратных задач различных геофизических методов. В работе Е.А. Оборнева [Оборнев, 2007] рассматриваются задачи интерпретации данных электроразведки. В работе показана эффективность применения нейронных сетей для решения инверсии двумерных магнитотеллурических данных для предварительного построения параметризованных геоэлектрических разрезов. Е.А. Оборнев получил набор обученных палеток, которые позволяют интерпретировать двумерные геоэлектрические разрезы, электропроводность которых определяется первыми сотнями параметров, без привлечения априорной информации о структуре разреза.

В диссертационной работе М.И. Шимелевича были разработаны методы, на основе нейронных сетей, для решения обратных задач геоэлектрики, объединяющие три ключевых подхода. Во-первых, это адаптивный регуляризованный метод, обеспечивающий решение, дифференцированное по глубине. Во-вторых, быстродействующий аппроксимационно-нейросетевой метод для задач высокой размерности. В-третьих, комбинированный аппроксимационно-итерационный метод уточнения результатов. Дополнительно создана методология оценки неоднозначности решений с использованием алгоритмов Монте-Карло. Эти разработки обеспечивают оптимальный баланс между детализацией и устойчивостью решений, позволяют получать результаты за десятки секунд независимо от сложности задачи, работают без начального приближения и применимы к средам любого типа [Шимелевич, 2024].

Значительный вклад в развитие нейросетевой интерпретации геофизических данных внесли работы В.В. Спичака. Разработанная им методология позволяет оценивать макропараметры геоэлектрических объектов непосредственно по данным электромагнитных зондирований [Спичак, Попова, 1998]. Модельные исследования показали возможность определения шести параметров с ошибкой 3-5% для геометрических характеристик. В монографии «Электромагнитная томография земных недр» [Спичак, 2019] систематизированы основы нейросетевого подхода к решению обратных задач геоэлектрики. Методология была успешно применена для прогноза температурных и фильтрационных свойств геотермальных резервуаров, показав ошибки прогноза менее 5% при экстраполяции на глубины, вдвое превышающие глубину скважины [Спичак, Захарова, 2023], что открыло перспективы, например, для оперативного прогноза свойств коллектора в процессе бурения.

Также существуют примеры применения нейронных сетей к интерпретации поля естественного электрического потенциала. В работе ученых из Саудовской Аравии [El - Kaliouby et al., 2009] рассмотрены каскады нейронных сетей на модельных примерах для инверсии аномалий естественного потенциала, связанных с моделями двумерных наклонных пластов (бесконечных по протяженности в направлении поперек профиля). Каскад нейронных сетей представляет собой последовательное применение независимых нейронных сетей, каждая из которых работает на отдельных входах для выполнения некоторой подзадачи. Анализируемыми параметрами являются глубина, полуширина, наклон и амплитуда поляризации. В работе инверсия сначала испытана на синтетическом примере, а затем рассмотрена на двух примерах полевых данных. Также в работе приведены оценки влияния случайного шума. Авторы работы высоко оценивают точность результатов инверсии на основе нейронных сетей и их согласованность с наблюдаемым полем по сравнению с другими используемыми методами инверсии.

Таким образом можно сделать вывод, что нейронные сети применяются во многих направлениях геофизики при решении различных частных задач. Но при этом на сегодняшний день повсеместной их интеграции в процесс обработки и интерпретации данных нет, что открывает перспективные возможности к исследованию их применения.

2.2. Применение нейронных сетей в гравirazведке и магниторазведке

Как отмечалось ранее, на сегодняшний день технологии машинного обучения, в частности нейронные сети, являются одними из самых быстро развивающихся направлений науки. При этом примеров их применения при обработке, анализе и интерпретации гравитационного и магнитного полей немного.

Важнейшим аспектом применения нейронных сетей, наряду с разработкой архитектур, является формирование качественных и репрезентативных наборов данных для обучения, что представляет собой отдельную сложную задачу в условиях неоднородности и большого объема геофизической информации.

Анализируя опубликованные работы, можно выделить несколько направлений приложения в гравиразведке и магниторазведке:

1. Решение обратных двумерных и трехмерных задач;
2. Выделение особенностей морфологии полей;
3. Восстановление морфологии структурных границ;
4. Обработка аэрогравиметрических данных;
5. Восстановление параметров потенциальных полей на площади.

2.2.1. Применение нейронных сетей для решения обратных задач гравиразведки и магниторазведки

Одной из ключевых проблем в интерпретации гравитационного и магнитного полей является решение обратной задачи. В класс таких задач входит подбор параметров изолированного аномалообразующего тела. Стоит отметить, что большинство работ, по теме применения нейронных сетей в задачах грави- и магниторазведки посвящено именно данному вопросу [Hesham, Mansour, 2009; Kaftan et al., 2011].

Рассмотрим его решение на примере работы коллектива авторов из кафедры геофизики инженерингового факультета Университета Dokuz Eylul, Турция [Kaftan et al., 2011]. В работе описано применение двух типов нейронных сетей для определения плотности источников в заданной сетке: многослойный перцептрон (MLPNN) (см. раздел 1.3.1) и сети радиальных базисных функций (RBFNN) (см. раздел 1.3.2). Оценка достоверности результатов выполнена на двух синтетических моделях и на примере полевых данных. Для модельных примеров, состоящих из двух тел простой формы (дайка и грабен), оценки глубин, положения и плотности, полученные с помощью MLPNN, так и RBFNN, по словам авторов работы совпали с заданными (Рисунок 10).

В работе показано, что результаты применения нейронных сетей позволяют восстановить положение и форму источников. При добавлении в сигнал шума 1% и 5% обе сети дают приемлемый уровень ошибок <10%. Погрешности при увеличении зашумленности сигнала увеличиваются. В целом, полученные результаты показывают, что расчетные параметры структуры близки к фактическим параметрам модели при амплитуде шума не более 10% от амплитуды аномального поля.

В конце работы алгоритмы MLPNN и RBFNN применены к реальным данным для проверки их согласованности. Данные результаты сравнивались с оценками, полученными в ходе ранее выполненных исследований. Несмотря на то, что в работе рассмотрен ограниченный ряд моделей, показано, что искусственные нейронные сети позволяют реконструировать геометрические параметры сеточных моделей.

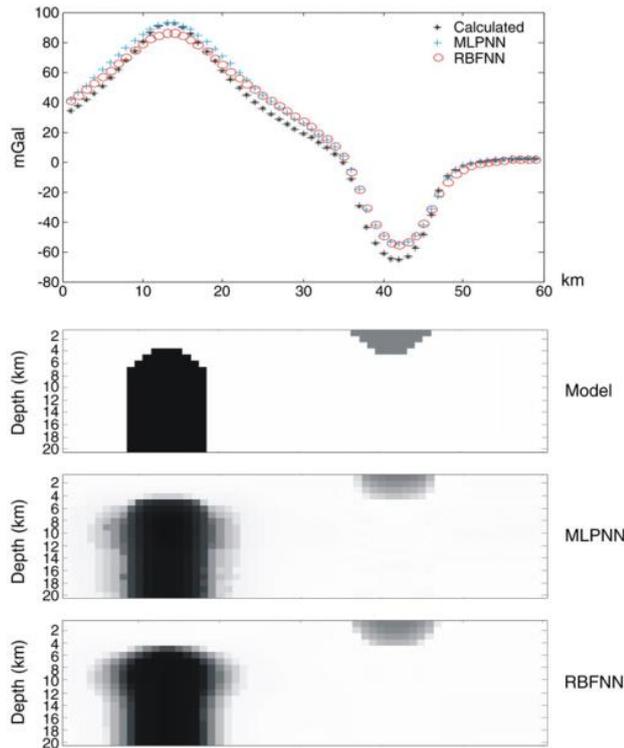


Рисунок 10 – Результаты подбора двумерной модели методами MLPNN (Многослойная нейронная сеть типа перцептрон) и RBFNN (Нейронная сеть радиально-базисных функций) [Kaftan et al., 2011]

В статье ученых из Японии [Elawadi et al., 2001] предложен простой подход для определения положения и радиуса пещер и туннелей по аномалиям силы тяжести. Латеральное положение источника определяется как проекция экстремума локальной аномалии, а его глубина оценивается с использованием обученной нейронной сети. Радиус рассчитывается на основе оценки избыточной плотности. Для решения обратной задачи использовалась трехслойная сеть прямого распространения с обратным распространением ошибки. Для обучения использовались 15 синтетических примеров для цилиндрических и сферических моделей полостей. Ошибки в оценках глубин составили менее $\pm 0.8\%$. После добавления случайного шума амплитудой до 10% к синтетическим данным точность определения глубин ухудшилась до $\pm 11.2\%$ для цилиндрических моделей и $\pm 8.1\%$ для сферических моделей (Рисунок 11). В статье также рассмотрен пример результатов полевых работ высокоточной гравиразведки, полученных над

пещерой Медфорд, штат Флорида, США с известными размерами. Расчетные параметры источников аномалий силы тяжести хорошо согласуются с параметрами, подтвержденными бурением. Таким образом в работе показана возможность оценки параметров изолированных источников потенциальных полей на основе нейронных сетей.

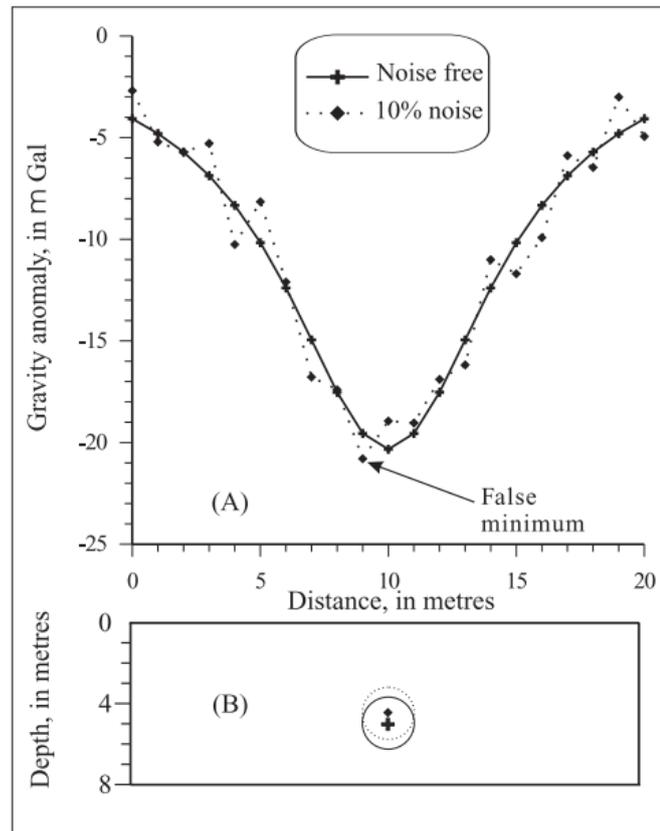


Рисунок 11 – Результаты применения нейронной сети к гравитационному эффекту модели цилиндра с радиусом 1 метр, эффективной плотностью 2.5 г/см^3 , расположенного на глубине 5 м (сплошная линия) и к зашумленным данным с добавленным 10% случайным шумом (пунктир) [Elawadi et al., 2001]

В работе ученых из университета Стамбула [Osman et al., 2006] рассмотрены примеры восстановления параметров двух синтетических моделей – горизонтальный цилиндр и тело Т-образной формы. Нейронные сети, представленные в статье, относятся к сетям типа перцептрон. Апробация алгоритма показала высокую сходимость расчетных результатов с модельными. В качестве приложения к реальным данным рассмотрены аномалии силы тяжести, приуроченные к соляному куполу, в районе северо-западной части Мексиканского залива. Результаты применения нейронной сети сравнивались с плотностной моделью, полученной подбором (Рисунок 12). Модель, полученная алгоритмом на основе нейронных сетей, отвечает меньшей невязке, чем метод подбора. Авторами отмечается, что преимущество предлагаемого подхода по

сравнению с классическими методами инверсии заключается в том, что нет необходимости в начальной информации о параметрах погребенной структуры, таких как глубина и ширина.

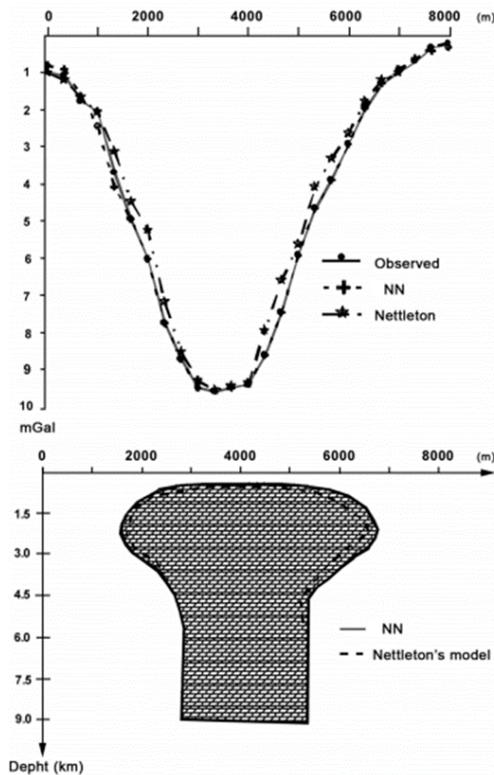


Рисунок 12 – Результат работы нейронной сети и метода подбора при решении обратной задачи гравirazведки для тела Т-образной формы [Osman et al., 2006]

В работах ученых из Китая [Bai et al., 2024; Yang et al., 2024] предлагается алгоритм решения двумерной обратной задачи на основе сверточной нейронной сети. Статья [Bai et al., 2024] посвящена применению методов глубокого обучения, в частности сверточных нейронных сетей, для совместной инверсии данных гравirazведки и магниторазведки. Авторы предлагают подход, который позволяет снизить зависимость от априорных данных и уменьшить вычислительные затраты по сравнению с традиционными методами, основанными на физических моделях. В работе модель источников представлена в виде равномерной прямоугольной сети. Предложен подход, основанный на обучении сети на большом наборе синтетических моделей, поле которых получено путем решения прямой задачи. Нейронная сеть представляет из себя последовательные слоев свертки с функцией активации ReLU и слоев сжатия (MaxPooling) с переходом в полносвязный слой из 800 нейронов (Рисунок 13).

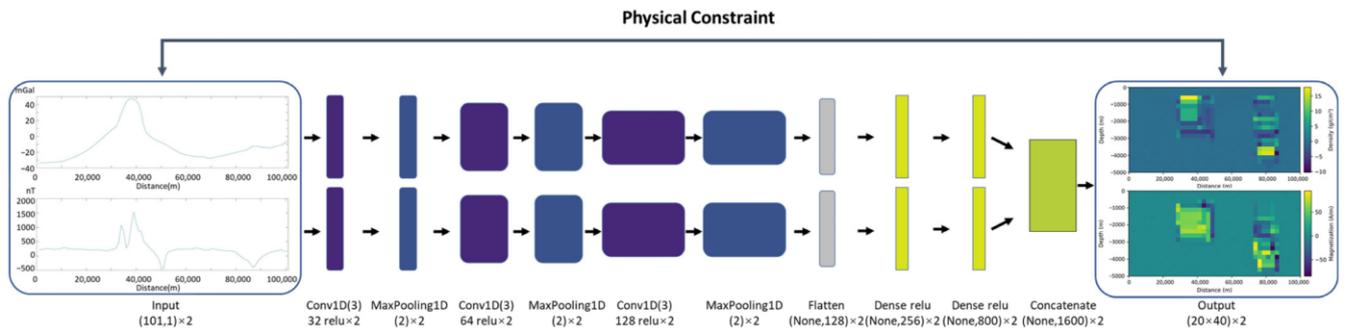


Рисунок 13 – Архитектура сети GMNet [Bai et al., 2024]

Для обучения сети сгенерированы 1368 синтетических моделей из 4 типов источников: одиночная призма; две горизонтально расположенных призмы; две вертикально расположенные призмы; ступень. Также в данные был добавлен гауссовский шум. Результаты применения нейронной сети позволили локализовать плотностные неоднородности, однако точность определения границ убывала с глубиной. Рассмотренный в работе подход также применен к полям региона Жуссары (Бразилия). Результаты инверсии показали наличие двух плотностных неоднородностей на профиле, согласующихся с аномалиями гравитационного и магнитного полей (Рисунок 14). Предложенная авторами нейронная сеть, названная GMNet, показала принципиальную возможность совместного решения обратной задачи для гравirazведки и магниторазведки, при этом значительно сокращая время вычислений и без привлечения априорной информации.

В работах ученых из Китая [Zhang et al., 2022; Jiao et al., 2024] предлагается алгоритм решения обратной трехмерной задачи на основе сверточной нейронной сети. В статье [Zhang et al., 2022] отмечается актуальность применения такого подхода, а также преимущество над обычными ручными или автоматическими методами, отличающихся неустойчивостью и высокими вычислительными затратами. В исследовании ученых из Китая представляется новый алгоритм построения трехмерных моделей по гравитационному полю (инверсия гравиметрических данных), основанный на СНС типа U-Net [Ronneberger et al., 2015]. Сеть имеет слои, которые составляют «кодировщик», определяющий необходимые признаки в гравитационном поле и «декодер», который переводит признаки в трехмерную плотностную структуру. Примеры применения нейронной сети для синтетически рассчитанных гравитационных полей выполнены с точностью порядка 97% и 81.5% при сокращении времени расчета в 20 раз в сравнении с классическими подходами в решении обратной задачи. В эксперименте с реальными данными (соляной купол Винтон) результат (Рисунок 15) хорошо согласуется с имеющейся у авторов геологической моделью. Рассмотренный в работе метод на основе СНС применим при решении обратной задачи гравirazведки.

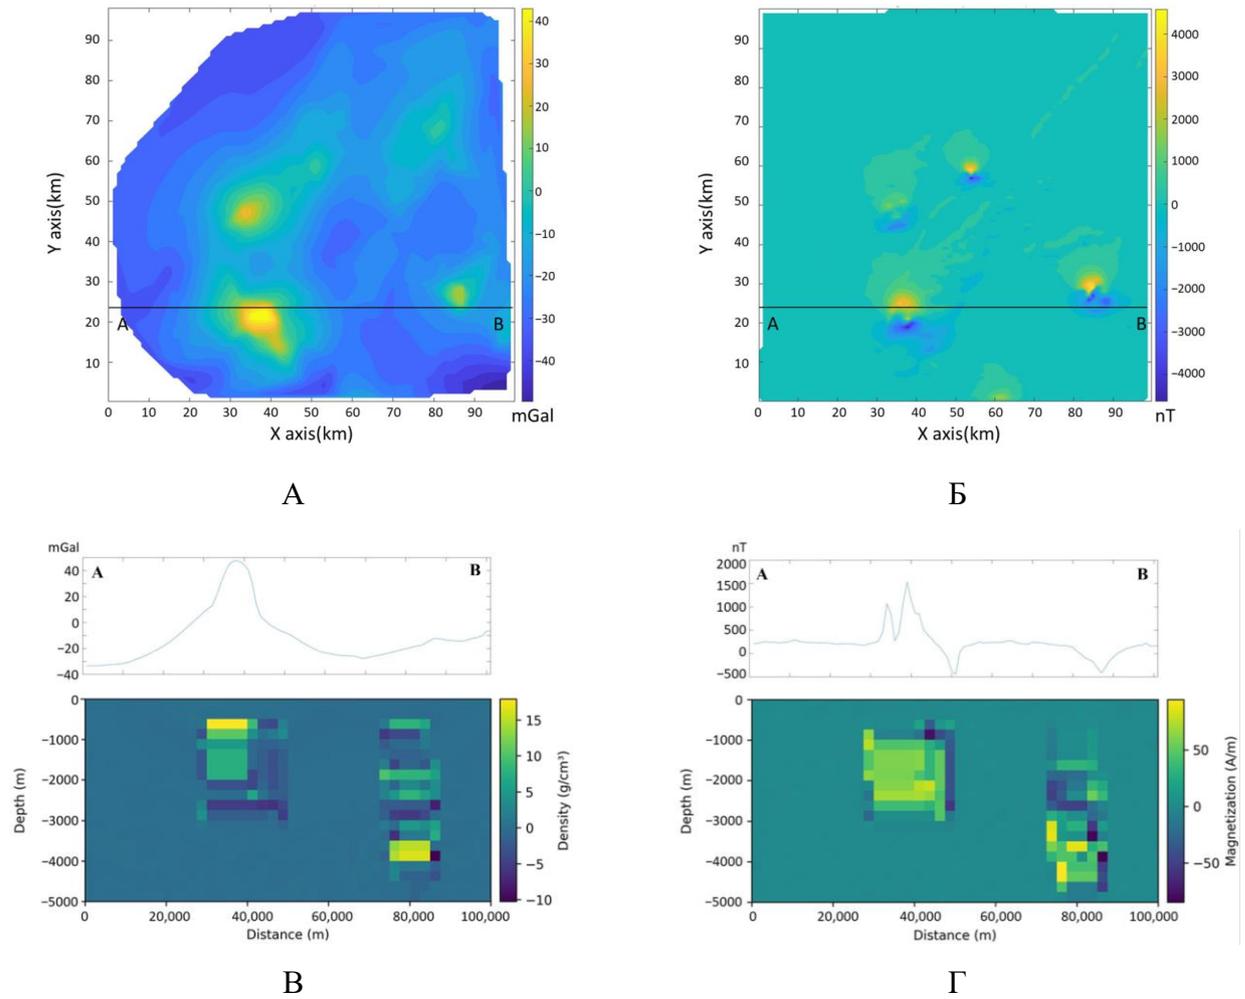


Рисунок 14 – Результаты инверсии с использованием метода машинного обучения GMNet на данных гравитационных (А) и магнитных (Б) аномалий [Вai et al., 2024]: В – инверсия по профилю АВ аномального гравитационного поля; Г – инверсия по профилю АВ аномального магнитного поля

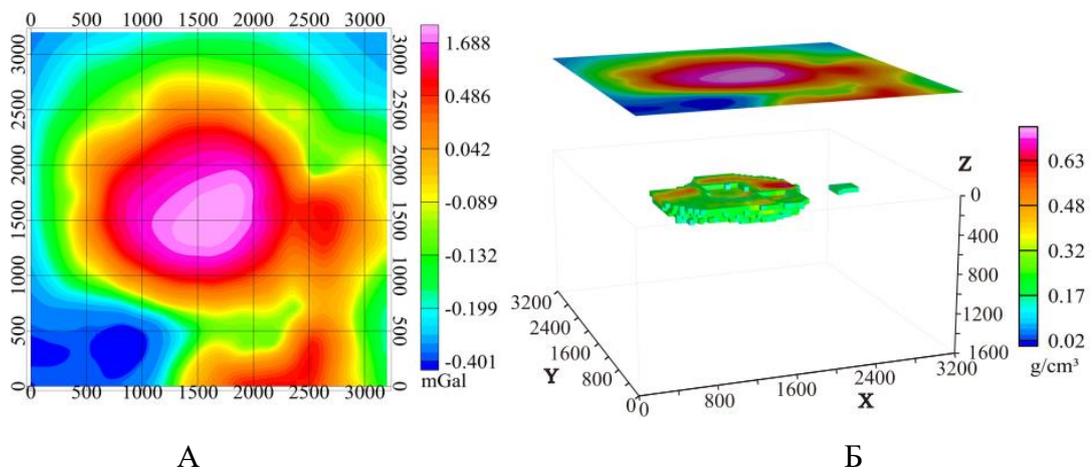


Рисунок 15 – Аномалия силы тяжести соляного купола Винтона (А) и рассчитанная с помощью СНС его объемная плотностная модель(Б) [Zhang et al., 2022]

2.2.2. Применение нейронных сетей для выделения морфологических особенностей гравитационного и магнитного полей

Одной из важнейших задач качественной интерпретации потенциальных полей является выделение их структурных особенностей. В работах исследователей из университета Стамбула, Турция [Aydogan et al., 2005; Aydogan, 2007; Aydogan, 2011] предложено решение задачи создания схемы линейных структур (линеаментов) с помощью клеточных нейронных сетей (КНС).

В перечисленных статьях для определения местоположения разломов или границ двух геологических зон представлена технология, называемая КНС, которая широко применяется при обработке изображений. Динамическая сеть КНС описывается системой дифференциальных уравнений. Каждая ячейка в КНС имеет вход, внутреннее слою и выход. В описанной статье алгоритм построения нейронной сети позволяет отнести его к сверточной (СНС). В статьях КНС применены к двум синтетическим наборам данных, состоящих из наборов вертикальных призматических блоков. Результаты метода обнаружения границ на основе нейронных сетей сравниваются с результатами, полученными с помощью алгоритма Кэнни [Canny, 1986]. После этого авторский подход применяется к аномалиям силы тяжести в редукции Буге для оценки положения линеаментов, приуроченных к разломам (Рисунок 16). Результаты предложенного подхода хорошо соотносятся с разломами, выделенными ранее.

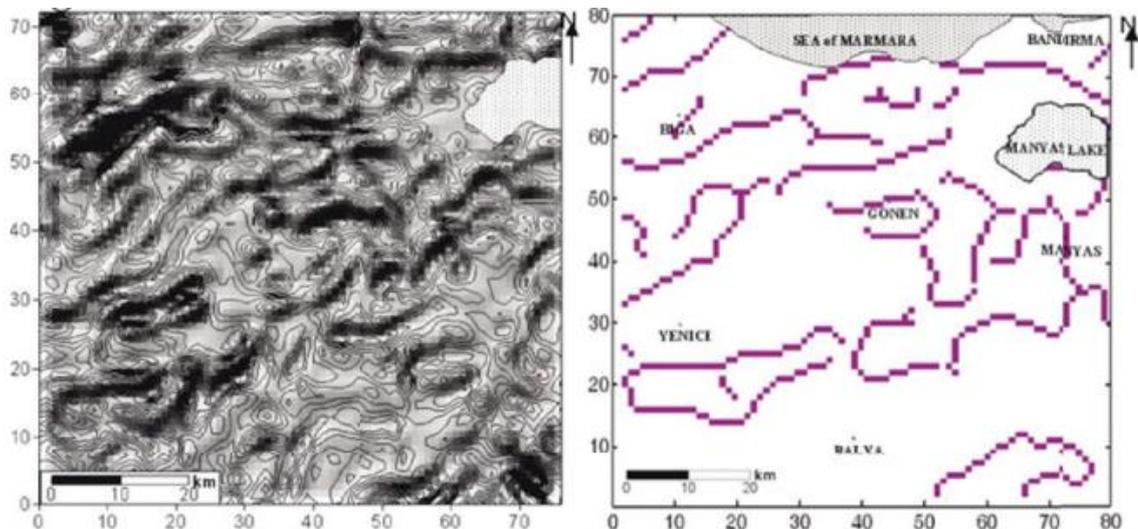


Рисунок 16 – Результат выделения структурных особенностей аномалий поля силы тяжести в редукции Буге с помощью сверточной нейронной сети [Aydogan, 2007]

В выводах к статье [Aydogan, 2011] авторы отмечают, что метод КНС, применяемый для определения местоположения границ блоков источников аномалий, прост и удобен в

использовании и является хорошим методом для определения вертикальных и субвертикальных элементов разреза. Таким образом, этот подход может быть полезным инструментом геофизики при исследовании на больших территориях.

В статье ученых из Китая [Zhou et al., 2024] представлен метод обнаружения границ источников аномального магнитного поля с использованием СНС U-Net с предобученными весами ResNet. Авторы пишут, что их подход, по сравнению с обычными методами подбора, позволяет восстановить положение границ тел на различных глубинах при небольших углах намагниченности и может быть применим без привлечения экспертной оценки. Для обучения СНС было создано 20 000 наборов синтетических данных с различным положением тел и случайными параметрами склонения и наклонения. Тестирование СНС на модельных данных различной сложности показало хороший результат: при использовании весов модели ResNet-34 точность по метрике Accuracy (см. раздел 1.4) составила 0.97, а по метрике Precision (см. раздел 1.4) – 0.91. Также предложенная в работе СНС протестирована на реальных данных аномального магнитного поля в Южно-Китайском море. Авторы рассмотрели цифровую модель аномального магнитного поля размером 64×64 ячейки (Рисунок 17). Они отмечают, что в результате (Рисунок 18) получаются незамкнутые кривые, что некорректно с точки зрения интерпретации. Тем не менее, алгоритм на основе СНС может стать эффективным инструментом для интерпретаторов.

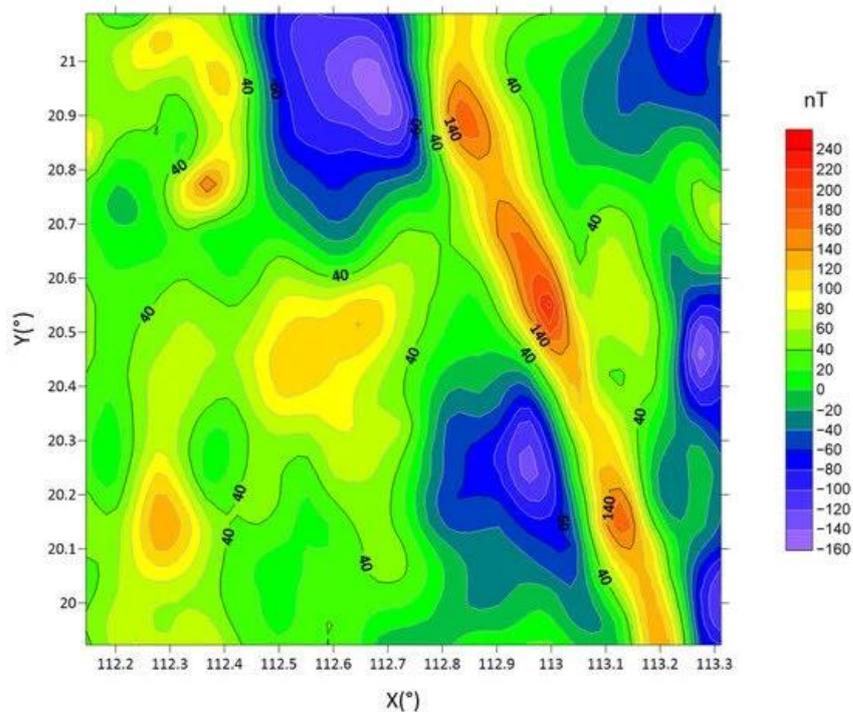


Рисунок 17 – Аномальное магнитное поле района исследования [Zhou et al., 2024]

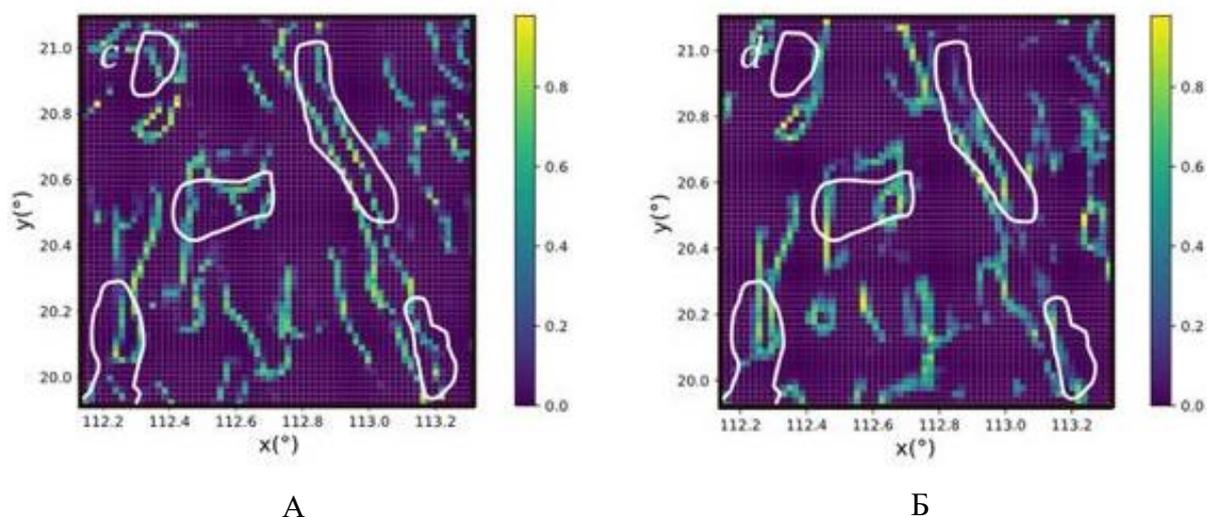


Рисунок 18 – Выявленные границы в аномальном магнитном поле. А – ResNet-34. Значения пикселей представляют вероятность границ; Б – ResNet-34 (после дополнительной настройки).

Белая линия – граница магматических пород, полученная с помощью экспертной интерпретации [Zhou et al., 2024]

В статье канадских ученых [Naprstek, Smith, 2022] приводятся исследования применения сверточных нейронных сетей для автоматической интерпретации линейных аномалий (предположительно связанных с дайками) в аэромагнитных данных. Основная цель работы – разработка метода, способного точно определять местоположение и глубину залегания даек, что является важной задачей при составлении геологических и тектонических схем.

Авторы отмечают, что традиционные методы интерпретации аэромагнитных данных, такие как tilt-depth (метод определения угла намагниченности и глубины источника) [Miller, Singh, 1994] и деконволюция Эйлера чувствительны к шумам. В отличие от них, СНС, успешно применяемые в обработке изображений и других геофизических задачах (например, в сейсморазведке), обладают высокой устойчивостью к высокочастотным помехам в поле.

Для обучения СНС авторы использовали синтетический набор данных, созданный с помощью программы GRAV_MAG_PRISM [Bongiolo et al., 2013]. Было рассчитано около 1.4 миллионов моделей полей с различными параметрами источников: глубиной, шириной, магнитной восприимчивостью и ориентацией даек. Данные дополнительно аугментировались вращением для увеличения обучающей выборки. Архитектура СНС включала сверточные слои, слои пулинга, дропаут для предотвращения переобучения и полносвязанные слои с функциями активации ReLU. Выходной слой использовал в качестве функции активации softmax для классификации глубины по заданным диапазонам.

Модель тестировалась на синтетических данных с разным уровнем шума (0.1 – 10 нТл) и сравнивалась с методом tilt-depth. Результаты показали, что СНС сохраняет высокую точность

даже при значительном уровне шума, тогда как результаты tilt-depth имеет значимую погрешность при шуме 3 нТл. Применение модели нейронной сети к реальным данным на территории северного Онтарио (Канада) (Рисунок 19) подтвердило её эффективность: глубина до верхней кромки дайки была определена верно (100-125 м против 111 м по данным бурения).

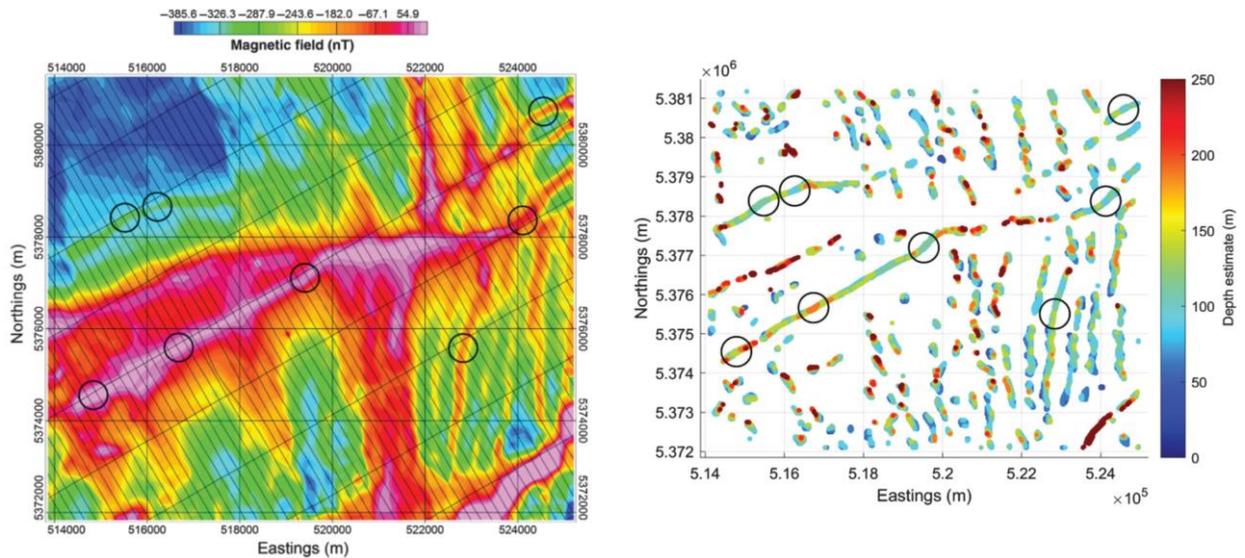


Рисунок 19 – Результат применения СНС (Б) к аномальному магнитному полю северного Онтарио (А). Черные круги – интересующие места [Naprstek, Smith, 2022]

Авторы делают вывод, что СНС являются мощным инструментом автоматической интерпретации аэромагнитных данных, особенно в условиях зашумленности или при обработке больших объемов информации. Они также отмечают, что метод требует значительных вычислительных ресурсов на этапе обучения, но в дальнейшем может быть легко применен к новым данным. В качестве направлений для будущих исследований предлагается расширение модели для оценки наклона даек, использование реальных данных для обучения, и адаптация метода для работы в низких широтах.

Проведенный анализ современных работ, посвященных применению сверточных нейронных сетей для выделения морфологических особенностей потенциальных полей, демонстрирует их несомненную эффективность, прежде всего, для решения задач структурного картирования – выделения линейных элементов, разломов и границ геологических тел. Однако можно констатировать, что существующие исследования в основном сфокусированы на обнаружении линейных или протяженных объектов. При этом, как показано в Главах 3 и 4 предложенная в настоящей работе методика на основе U-Net с предобученным энкодером VGG-16 не только решает ранее недостаточно изученную задачу сегментации изометричных

аномалий, но и демонстрирует более высокую эффективность при выделении линейных структур в сравнении с рассмотренными выше подходами.

2.2.3. Применение нейронных сетей при обработке аэрогравиметрических данных

Одной из важнейших задач обработки аэрогравиметрических данных является учет возмущающих ускорений, действующих на гравиметр и их разделение с ускорением силы тяжести. В статье украинских ученых [Bezvesilna et al., 2017] предложен инструментальный алгоритм для решения данной задачи с помощью нейронной сети. Рассмотрена идея усовершенствования авиационной гравиметрической системы за счет введения дополнительного вычислительного блока нейронной сети на борту воздушного судна. Предлагается, что на вход в него подаются сигналы горизонтальных акселерометров и показания гравиметра. Результаты работы нейронной сети подаются на вычислительный блок (ODCM) (Рисунок 20).

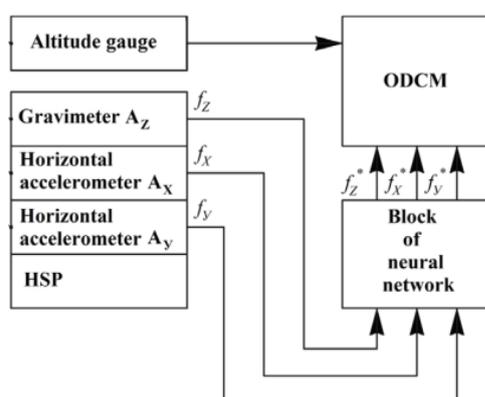


Рисунок 20 – Схема автоматизированной системы с компенсацией ошибок измерения аномалий силы тяжести с помощью блока нейронной сети [Bezvesilna et al., 2017]

Авторами статьи предполагается, что поскольку блок нейронной сети выполняет компенсацию инструментальных погрешностей гравиметра и двух горизонтальных акселерометров, то будет обеспечено существенное повышение точности измерений. Однако важно отметить, что в статье не приведены примеры с результатами работы предлагаемого подхода.

2.2.4. Построение моделей гравитационного поля Земли с помощью нейронных сетей

Одной из задач гравиметрии является создание моделей гравитационного поля всей Земли. В работе ученого из Турции [Turgut, 2016] рассмотрен подход на основе многослойных нейронных сетей с обучением методом обратного распространения ошибки к восстановлению параметров гравитационного поля Земли по результатам измерений абсолютных гравиметров,

находящихся в обсерваториях, на примере штатов Калифорния, Аризона, Невада, Юта (США). Для расчетов использовались материалы 56 пунктов: 32 для расчетов и 24 для оценки точности. На рисунке 21 представлены карты точности построения моделей гравитационного поля, полученные по оценкам в 24 точках. Для сравнения оценки выполнены как для результатов работы алгоритма, так и для моделей EGM2008 и EIGEN-6C4. В работе авторы отмечают, что среднеквадратическое расхождение для метода на основе нейронных сетей меньше, чем для существующих моделей.

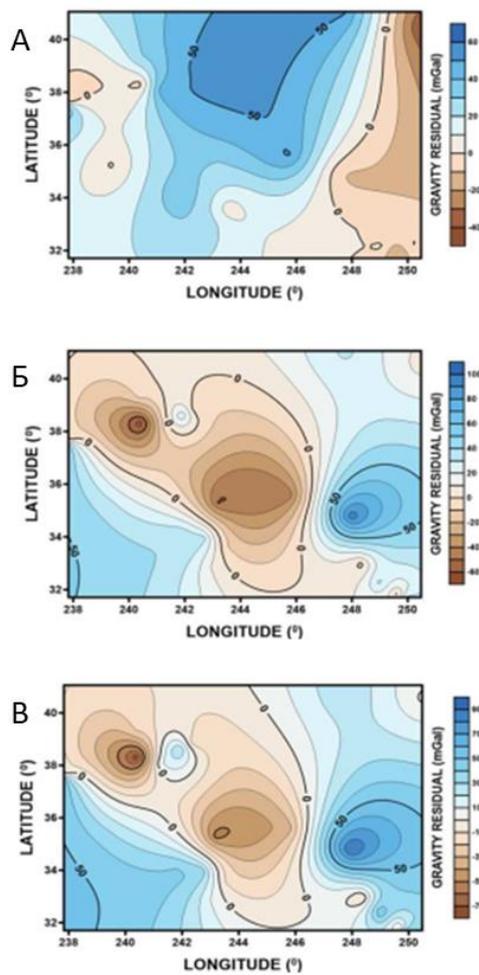


Рисунок 21 – Карты невязок моделей гравитационного поля, построенные по 24 пунктам, используемых для оценки точности [Turgut, 2016]:

А – Результат работы нейронной сети; Б – Модель гравитационного поля EGM2008; В – Модель гравитационного поля EIGEN-6C4

2.2.5. Применение нейронных сетей при восстановлении морфологии структурных границ по гравитационному и магнитному полям

В последние годы актуальной задачей является восстановление морфологии структурных границ по данным потенциальных полей и сейсморазведки с обучением на эталонном участке. Одной из наиболее заметных работ в этом направлении в российской практике является исследование, выполненное специалистами АО «ГНПП Аэрогеофизика» под руководством А.В. Колмакова [Колмаков и др., 2020; Колмаков, 2021; Колмаков, 2023]. В своей статье авторы предлагают комплексный подход, использующий методы машинного обучения для интерполяции и экстраполяции структурных горизонтов в межпрофильном пространстве на основе плотных площадных данных гравиразведки и магниторазведки. На модельных данных авторы демонстрируют, что использование нейронной сети позволило снизить ошибку восстановления горизонта фундамента в межпрофильном пространстве с 176.88 м (классическая интерполяция) до 67.78 м, а на реальном примере для горизонта осадочного чехла достигнута точность СКО 18.75 м после оптимизации [Колмаков, 2023], что подтверждает высокий потенциал метода (Рисунок 22).

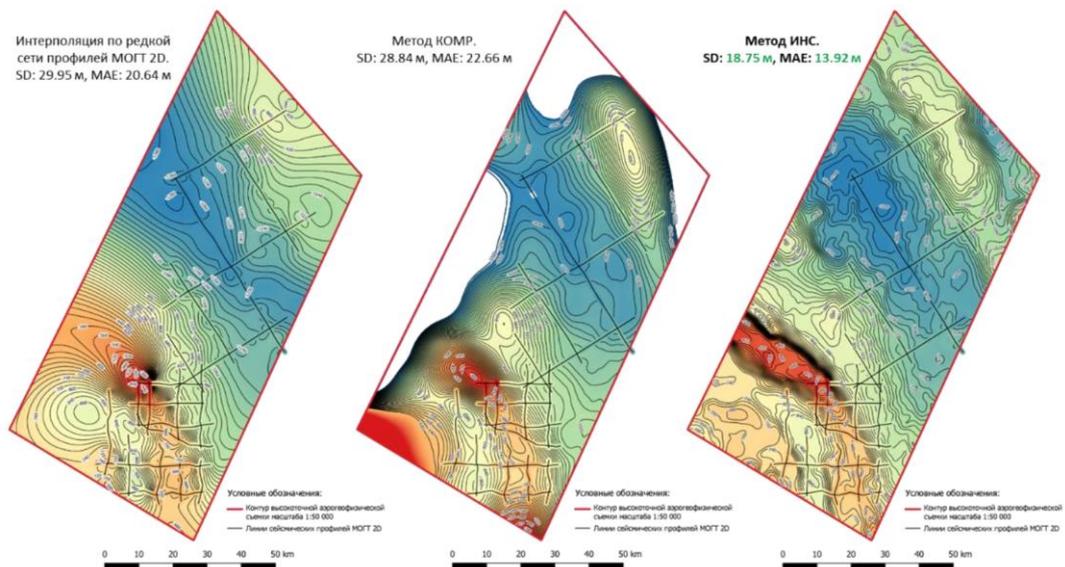


Рисунок 22 – Анализ различных методов интерполяции [Колмаков, 2021]

Однако высокие показатели точности, достигнутые в работе [Колмаков, 2023], хотя и важны, не дают представления о надежности метода и границах его применимости. Исследование носит демонстрационный характер и оставляет открытыми ключевые для практики методические вопросы. В частности, не проведено системное исследование зависимости точности от степени разреженности опорных сейсмических данных, что не

позволяет оценить минимальный объем сейсмических наблюдений для работы алгоритма на новой площади. Не изучена устойчивость алгоритма к зашумленности геофизических полей – фактору, неизбежному в реальных условиях. Выбор архитектуры нейронной сети остается эмпирическим, а валидация в условиях экстраполяции, наиболее востребованной на ранних стадиях ГРП, является ограниченной. Таким образом, работа подтверждает принципиальную возможность, но не дает инструмента для его прогнозируемого применения в разнообразных реальных условиях.

Настоящее диссертационное исследование направлено на преодоление этих методических ограничений путем перевода подхода из области демонстрации успешных примеров в область количественно обоснованной технологии. В ходе проведенного модельного эксперимента (Глава 5) была не только подтверждена возможность достижения высокой точности, но, что важно, установлены количественные границы и условия его устойчивой работы. В разделе 5.2 показано, что для надежного восстановления горизонта с ошибкой около 100-110 м достаточно данных с профилей, покрывающих лишь 5% площади. В разделе 5.3 на реальных данных при сравнимой степени разрежения также получена высокая точность (СКО 7-10 м для полного набора данных), что подтверждает эффективность метода. Главным же отличием является исследование устойчивости: разработан и апробирован механизм борьбы с зашумленностью (обогащение выборки трансформантами полей), позволивший при 50% уровне шума улучшить точность в 4 раза. Проведено системное сравнение 13 архитектур нейронных сетей, давшее рекомендации по оптимизации, и комплексная валидация, доказавшая превосходство нейросетей в задачах экстраполяции. Таким образом, в отличие от предшествующих работ, настоящее диссертационное исследование не только демонстрирует отдельные успешные случаи, но и формирует завершённую методику с предсказуемой точностью и известными пределами надёжности для работы в условиях неполных и зашумлённых данных.

2.2.6. Методологические аспекты подготовки геолого-геофизических данных для обучения нейронных сетей

Применение нейронных сетей в геофизике требует решения задачи сбора, предварительной обработки и объединения разнородных данных. По существующим оценкам, этот этап занимает до 80% времени и ресурсов в проектах, связанных с анализом данных. В работе Лисенкова И.А. и др. [Лисенков и др., 2025] представлен подход к формированию единого набора данных для применения моделей машинного обучения, включая нейронные сети, для решения геофизических задач.

Авторы рассматривают проблемы работы с геопространственными данными: различия в форматах (векторные или растровые данные), масштабах, типах описательной информации

(количественная или качественная) и их доступности. В качестве решения предлагается архитектура программно-аппаратного комплекса. Она включает модуль сбора и преобразования данных на языке Python с использованием библиотеки Pandas, а также систему хранения на основе СУБД PostgreSQL с расширением PostGIS для работы с пространственными данными (Рисунок 23).

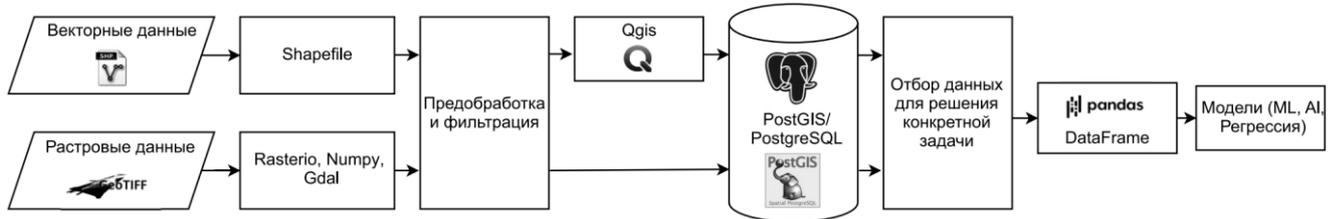


Рисунок 23 – Общая архитектура комплекса подготовки пространственных геолого-геофизических данных [Лисенков и др., 2025]

Основным элементом методики является использование понятия «окрестности» для отбора и объединения информации. Для заданного региона формируется сетка окружностей или прямоугольников, для каждой из которых собираются все доступные геолого-геофизические показатели из различных источников.

Это позволяет преобразовать разнородную пространственную информацию в числовые векторы, пригодные для обучения моделей. Качественные данные (например, типы рельефа или почв) преобразуются с помощью прямого кодирования, когда каждому категориальному значению ставится в соответствие отдельный двоичный признак.

В рамках работы был собран массив данных для восточного сектора Российской Арктики, содержащий 43 783 записи с 227 параметрами, включая данные о рельефе, магнитных и гравитационных аномалиях, активных разломах и сейсмичности [Lisenkov et al., 2024]. На примере задачи распознавания мест возможных землетрясений на Кавказе показана эффективность предложенной методики.

Таким образом, работа [Лисенков и др., 2025] систематизирует подход к подготовке данных, что необходимо для применения нейронных сетей при комплексном анализе геолого-геофизической информации.

2.2.7. Заключение о применимости нейронных сетей в гравиразведке и магниторазведке

Несмотря на то, что термин «нейронная сеть» появился в середине прошлого века, применение их в гравиразведке и магниторазведке началось сравнительно недавно. Обзор публикаций показал, что нейронные сети различных типов могут найти свое применение в

решении задач обработки и интерпретации. Многие авторы отмечают, что наиболее трудоемкой частью работы с ними является их обучение. При этом зачастую обучение выполняется не на реальных данных, а на синтетически рассчитанных. Также важно отметить, что большинство публикаций посвящено вопросам принципиальной возможности использования нейронных сетей в гравirazведке и магниторазведке, что открывает широкие возможности исследования их применимости.

2.3. Выводы по Главе 2

Проведенный обзор современного состояния применения нейронных сетей в геофизике позволяет констатировать, что данный математический аппарат зарекомендовал себя как эффективный инструмент для решения широкого спектра задач, связанных с обработкой и интерпретацией геофизических данных. Хотя стоит отметить, что методы искусственного интеллекта в геофизике получили наибольшее развитие в анализе данных сейсморазведки.

Наибольшее практическое развитие применения нейронных сетей в гравirazведке и магниторазведке получили два ключевых направления. Первое – решение обратных задач, где сверточные нейронные сети и архитектуры типа U-Net позволяют восстанавливать пространственное распределение плотностных или магнитных неоднородностей с точностью, сопоставимой с традиционными методами инверсии, но со значительным выигрышем в скорости вычислений и с меньшей зависимостью от априорных данных. Второе направление – автоматизированный структурный анализ, в рамках которого те же архитектуры успешно применяются для детектирования границ геологических объектов, выделения линейментов и оценки глубины залегания источников, демонстрируя при этом робастность к высокочастотным помехам. Также нейронные сети применяются в таких частных задачах, как создание моделей полей, обработка полевых аэрогравиметрических наблюдений.

Анализ публикаций также выявляет проблему формирования качественных и репрезентативных обучающих выборок. Успешность обучения нейросетевых моделей в значительной степени определяется корректностью подготовки данных, что с одной стороны включает унификацию разнородной геолого-геофизической информации и разработку специализированных программно-аппаратных комплексов для управления пространственными данными, а с другой – подготовку синтетических данных и подходов к их созданию.

Таким образом, несмотря на растущее количество публикаций, применение нейронных сетей в интерпретации потенциальных полей остается областью активных исследований, где сохраняется значительный потенциал для разработки новых специализированных архитектур и комплексных методик. Полученные теоретические и практические выводы формируют необходимую основу для дальнейшего исследования, представленного в данной работе, и

обосновывают целесообразность разработки и адаптации нейросетевых методов для повышения эффективности и объективности анализа аномальных гравитационных и магнитных полей.

Глава 3. Выделение изометричных аномалий в гравитационных и магнитных полях на основе сверточных нейронных сетей¹

Автоматическое выделение изометричных аномалий в потенциальных полях представляет собой важную задачу для составления схем аномалий на первых этапах качественной интерпретации. Традиционные методы обработки данных сталкиваются с существенными ограничениями при идентификации слабоконтрастных или перекрывающихся аномалий, особенно в условиях сложного фонового поля. Разработка эффективных методов автоматизированной интерпретации таких объектов приобретает особую актуальность в связи с ростом объемов геофизических данных и необходимостью их оперативного анализа.

В данной главе рассматривается задача автоматизированного выделения изометричных аномалий на основе сверточных нейронных сетей. Приведенный пример позволяет в деталях рассмотреть разработку универсального подхода, включающего:

1. Создание синтетических обучающих выборок, моделирующих различные типы изометричных аномалий;
2. Оптимизацию архитектуры нейронной сети для задач сегментации гравитационного и магнитного полей с целью выделения изометричных аномалий.

Не уменьшая общности подхода, для демонстрации эффективности предложенного метода рассмотрим его применение к гравитационному полю Луны. Основным методом изучения гравитационного поля Луны является исследование возмущений орбит её искусственных спутников. Эти исследования позволили установить общую асимметрию и неоднородность распределения масс в теле спутника Земли. При запуске первых искусственных спутников Луны обнаружены аномальные участки, в пределах которых они сильно отклонялись от расчетных орбит. Такие объекты были названы «масконами» (от англ. *mass concentration*) и предположительно связаны с областями повышенной плотности (концентрациями масс), расположенными в пределах лунной коры, создающими высокоамплитудные (до нескольких сотен мГал) аномалии поля силы тяжести. Впервые они были выделены в гравитационном поле в работе Мюллера и Шергена [Muller, Sjogren, 1968] в 1968 году по особенностям в движениях искусственных спутников Луны. Чаще всего масконы расположены под лунными морями,

¹ При подготовке данного раздела диссертации использована следующая публикация, выполненная автором в соавторстве, в которой, согласно Положению о присуждении ученых степеней в МГУ, отражены основные результаты, положения и выводы исследования:

имеющими округлую форму. Наиболее крупные из них расположены в Море Дождей, Море Ясности, Море Кризисов и др. [Сагитов, 1979].

Природа гравитационных аномалий масконов и история их формирования на сегодняшний день остается дискуссионной. Предположительно они являются результатом крупных ударных событий и последующего заполнения образовавшихся бассейнов плотным базальтовым материалом на ранних этапах истории формирования Луны [Head, Wilson, 1992]. Однако аномалии базальтовых слоев мощностью даже в несколько километров не могут объяснить наличие столь амплитудных аномалий силы тяжести [Ситникова, 2025]. Ряд исследователей связывает их природу с поднятиями в мантии Луны [Neumann et al., 2015].

В гравитационном поле масконы проявлены положительными изометричными аномалиями амплитудой от десятков мГал до 650 мГал (море Москвы и море Восточное). Их диаметр меняется в широком диапазоне: от 110 км (Д'Аламбер) до 1000 км (море Южное). На рисунке 24 приведены аномалии силы тяжести в редукции Буге модели GRGM1200A с плотностью промежуточного слоя 2.55 г/см^3 , отвечающей средней плотности лунной коры [Goossens et al., 2016]. Модель получена по результатам обработки данных спутниковой миссии GRAIL и хранится в виде коэффициентов разложения гравитационного потенциала на сферические гармоники (число 1200 в названии модели означает количество сферических гармоник). Для лунной экваториальной области пространственное разрешение модели составляет порядка $10 \text{ км} \times 10 \text{ км}$. Модель рельефа, учитываемого при вычислении аномалий в редукции Буге получена на основе данных лазерной альтиметрии миссии Lunar Orbiter (LOLA) [Goossens et al., 2016].

Гравитационные эффекты масконов сопоставимы по амплитуде с аномалиями силы тяжести, связанными с элементами глубинного строения Луны, но имеют существенно более высокие горизонтальные градиенты. Данное обстоятельство является существенной помехой для построения непрерывной плотностной модели небесного тела. Таким образом необходимо разработать подход, позволяющий локализовать эффекты масконов для дальнейшего их исключения из гравитационного поля. В работе предложен метод локализации масконов Луны в аномалиях поля силы тяжести на основе сверточных нейронных сетей.

В последние годы технологии на основе нейронных сетей стали мощным инструментом для решения разного рода задач локализации объектов на изображениях – задач семантической сегментации. Выделение контуров аномалий масконов в гравитационном поле Луны можно отнести именно к ним. Наиболее эффективным подходом для семантической сегментации изображений является использование сверточных нейронных сетей [Хайкин, 2006].

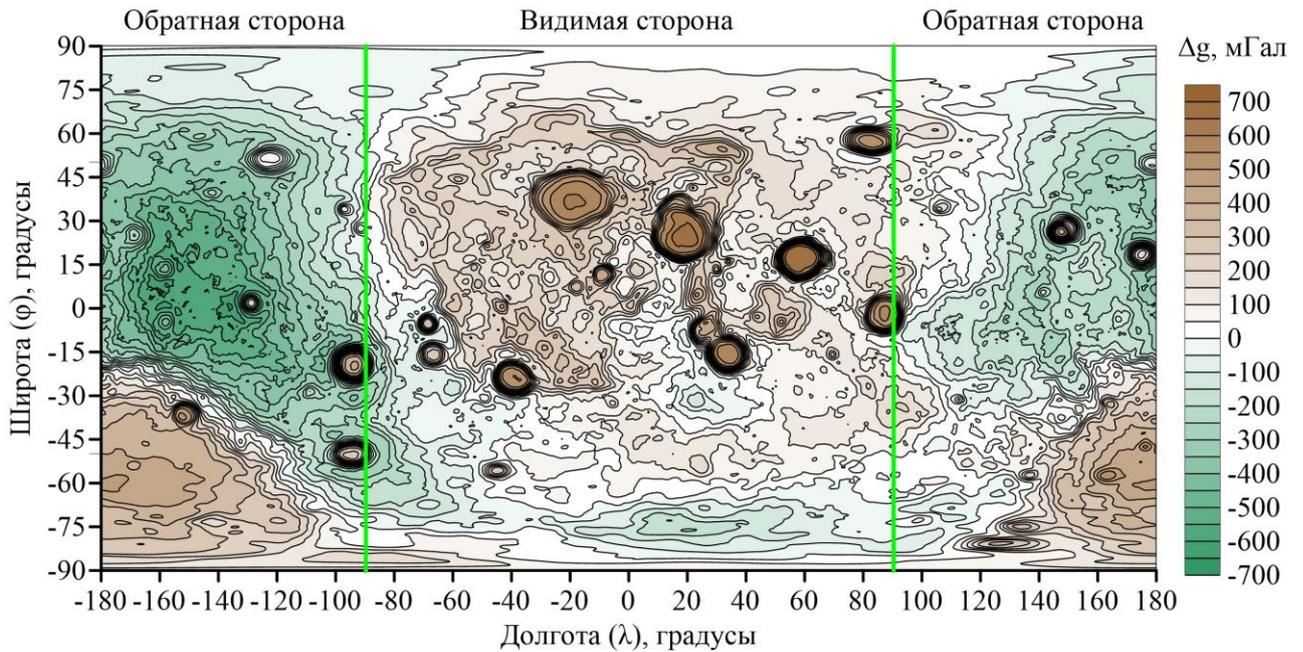


Рисунок 24 – Проявленность масконов в аномалиях силы тяжести в редукции Буге с плотностью 2.55 г/см^3 модели GRGM1200A [Goossens et al., 2016]. (Сечение изолиний 50 мГал)

3.1. Методика создания синтетической обучающей выборки для выделения изометричных аномалий в аномальном гравитационном поле Луны

На практике для выбора метода выделения аномалий и оптимизации его параметров необходима достаточно большая обучающая выборка. При этом каждый набор вход-выход должен быть близок по своим параметрам (амплитуда и ширина локальных аномалий, спектр поля) к анализируемым данным, в данной работе – к аномалиям масконов Луны.

Гравитационные аномалии лунных масконов являются уникальными, их сомасштабные аналоги на Земле отсутствуют. Кроме того, автору не известны общедоступные базы, в которых содержались бы примеры гравитационных полей с выделенными аномалиями, или такие наборы, которые можно было бы использовать в виде аналогов. В связи с этим актуальной задачей является создание набора синтетических примеров, которые могли бы выступить в виде обучающей, валидационной и тестовой выборок.

Гравитационное поле в окрестности маскона содержит помимо эффекта самого маскона также региональную и локальную компоненты поля силы тяжести (Рисунок 24). Спектры указанных трех частей гравитационного поля пересекаются и методами частотной фильтрации разделены быть не могут. Поэтому при создании каждого синтетического примера должны быть применены механизмы моделирования всех трех компонент. Создание обучающей выборки происходит в 4 этапа.

1. *Моделирование гравитационных эффектов масконов.* При сопоставлении гравитационных полей тел простой геометрической формы (которые вычисляются относительно

просто и быстро) с полями масконов выяснено, что наиболее эффективной для моделирования является третья вертикальная производная потенциала V_{zzz} точечного источника с точки зрения минимизации вычислительного времени и близости форм. На рисунке 25 представлено сопоставление различных вертикальных производных гравитационного потенциала точечного источника с аномалиями двух характерных масконов Крюгер-Серсалис и море Москвы.

Вертикальные производные гравитационного потенциала точечного источника ниже третьего порядка не соответствуют форме гравитационных аномалий масконов на их границах – градиенты модельного поля не совпадают с градиентами наблюдаемого. Гравитационный эффект маскона моделируется третьей вертикальной производной потенциала (V_{zzz}) точечного источника, вычисляемой по формуле:

$$V_{zzz} = GM \left(\frac{15z^3}{r^7} - \frac{9z}{r^5} \right), \quad (16)$$

где G – гравитационная постоянная, M – масса точечного источника, z – глубина источника, r – расстояние от точки расчета до источника.

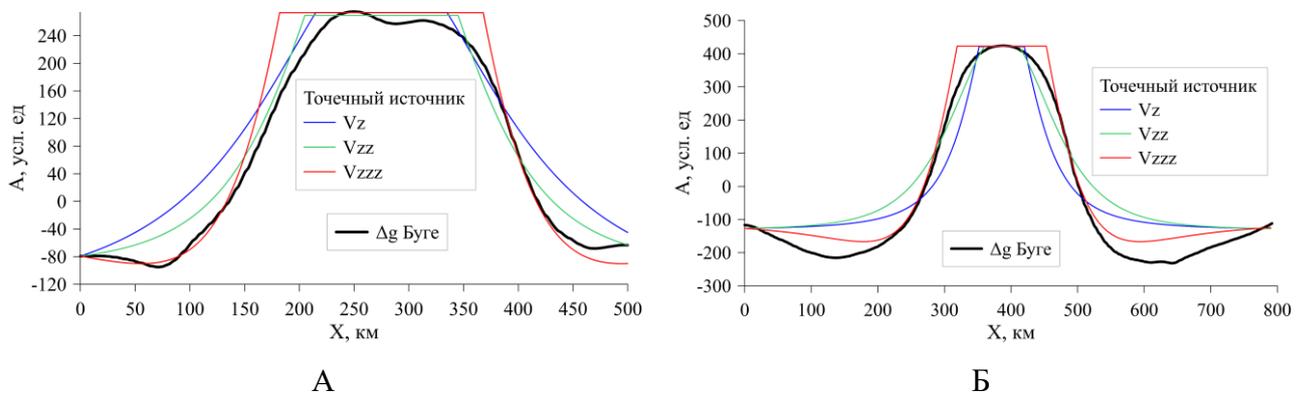


Рисунок 25 – Графики нормированных значений аномалий силы тяжести в редукции Буге и вертикальных производных V_z , V_{zz} , и V_{zzz} точечных источников над масконами Крюгер-Серсалис (А) и море Москвы (Б)

Параметры точечного источника (положение в пространстве, масса) для создания синтетической выборки из сотен или тысяч примеров задаются случайным образом. Единственным ограничением является амплитуда вычисляемого эффекта. Поскольку большинство аномалий масконов имеют «пологую» область экстремума (Рисунок 25А), то рассчитываемое поле обрезается по случайно заданному уровню. Отрицательные значения заменяются на нулевые для исключения сопутствующих минимумов, возникающих при расчете

3. Путем суммирования трех синтезированных компонент создается модель гравитационного поля, которая предназначена для обучения нейронной сети (входная карта) (Рисунок 26).

4. В качестве карты локализации положения масконов Луны создается бинарная маска (выходная карта): область, где нормированные значения гравитационного эффекта точечных источников превышают 0.5 усл. ед. (по границе максимального градиента) (Рисунок 26):

- «1» – область маскона (значения ≥ 0.5);
- «0» – фон (значения < 0.5).

В одном наборе данных «поле – маска» может присутствовать от 1 до 10 источников, моделирующих поле масконов (Рисунок 26).

3.2. Подготовка данных аномального гравитационного поля Луны для применения обученной СНС

Для последующего применения методов машинного обучения (в частности, сверточных нейронных сетей) к реальным данным требовалась специальная предобработка данных о гравитационном поле Луны. В качестве исходных данных использована модель аномалий силы тяжести в редукции Буге с плотностью промежуточного слоя 2.55 г/см^3 GRGM1200A (Рисунок 24). Масконы в данном поле проявляются изометричными положительными аномалиями. В экваториальной области такие аномалии имеют форму, близкую к окружности, а при удалении от экватора к полюсам меняют ее на эллипсоидальную, что связано с отображением данных в географической системе координат на плоскости. Для сохранения формы аномалий модель поля была спроецирована в равноугольную проекцию Меркатора (Рисунок 27).

Поскольку типичные архитектуры сверточных нейронных сетей эффективно работают с данными, размерность которых кратна степени двойки (в нашем случае – 32), для работы был выбран размер входного изображения 192×192 пикселей. Данный размер представляет собой оптимальный компромисс:

- Меньшие размеры (например, 64×64 или 128×128) не позволяют модели эффективно обучаться, так как приводят к значительной потере пространственного разрешения и информации о форме аномалий.
- Использование больших размеров (256×256 и более) требует существенно больших вычислительных ресурсов и объемов памяти, превышающих возможности стандартных рабочих станций (ПК).

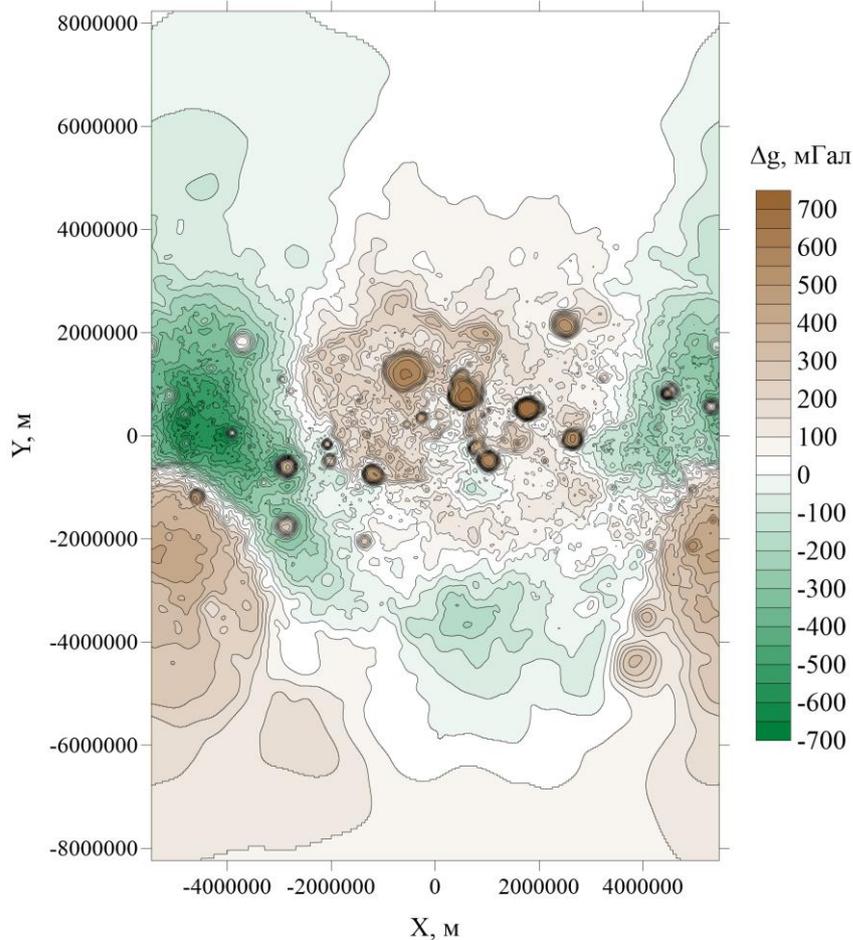


Рисунок 27 – Аномалии силы тяжести в редукции Буге Луны в проекции Меркатор

Исходная модель гравитационного поля, имеющая размер 701×546 точек в выбранной проекции, была расширена до размеров, кратных 192. Для применения сети всё поле разбивалось на блоки размером 192×192 . Для обеспечения непрерывности данных и минимизации потери информации на границах таких блоков использовалось их перекрытие на 75%. Этот подход позволил значительно улучшить точность локализации масконов, находящихся на стыках обрабатываемых областей.

Кроме того, для совместимости с методами машинного обучения аномальное поле силы тяжести Луны было нормировано. С целью подавления влияния выбросов и экстремальных значений использовался метод RobustScaler [Pedregosa et al., 2011], который привел данные к единому масштабу.

3.3. Экспериментальное исследование и оптимизация архитектуры СНС

Для выбора оптимальной архитектуры были проведены эксперименты с различными предобученными моделями сверточных нейронных сетей. Целью этих экспериментов было

определение эффективной архитектуры модели для решения задачи локализации масконов Луны.

3.3.1. Сравнительный анализ архитектур U-Net

Для всестороннего анализа эффективности различных архитектур глубокого обучения применительно к задаче сегментации изометричных гравитационных аномалий проведено сравнение пяти современных модификаций U-Net-подобных сетей (Рисунок 28):

1. U-Net [Ronneberger et al., 2015] – базовая архитектура представляет собой симметричную структуру, где энкодер последовательно уменьшает пространственное разрешение данных, выделяя иерархические признаки, а декодер восстанавливает исходное разрешение. Особенностью модели являются прямой перенос весов, передающие высокочастотные компоненты из энкодера в соответствующие уровни декодера.

2. U-Net++ [Zhou et al., 2018] – усовершенствованная версия U-Net с плотными соединениями между всеми уровнями энкодера и декодера. В отличие от классической архитектуры, где соединения идут только между соответствующими уровнями, U-Net++ создает сложную сеть взаимосвязей, позволяющую комбинировать признаки разного масштаба.

3. UNet 3+ [Huang et al., 2020] – архитектура с полномасштабными соединениями, где каждый уровень декодера получает информацию со всех уровней энкодера. Для этого используются операции понижающей и повышающей дискретизации, а также агрегация признаков через слои объединения.

4. Attention U-Net [Oktay et al., 2018] – модификация U-Net с механизмом «внимания» в переносе весов. В отличие от классической версии, перед передачей признаков из энкодера в декодер они проходят через дополнительный блок, который автоматически определяет наиболее значимые области для сегментации.

5. R2U-Net [Alom et al., 2018] – гибридная архитектура, сочетающая подход U-Net с рекуррентными связями. Каждый блок сети содержит дополнительную рекуррентную структуру, позволяющую итеративно уточнять признаки.

Все рассматриваемые архитектуры используют общий принцип энкодер-декодера, однако существенно различаются в способах организации межслойных взаимодействий и механизмах извлечения пространственных признаков. Все модели обучались на одной выборке из 500 синтетических карт аномального гравитационного поля с использованием 100 карт для валидации и 100 карт для тестирования. Для обеспечения корректного сравнения большинство моделей использовали идентичный предобученный энкодер VGG-16, за исключением R2U-Net, для которой невозможно применение предобученных весов такого формата.

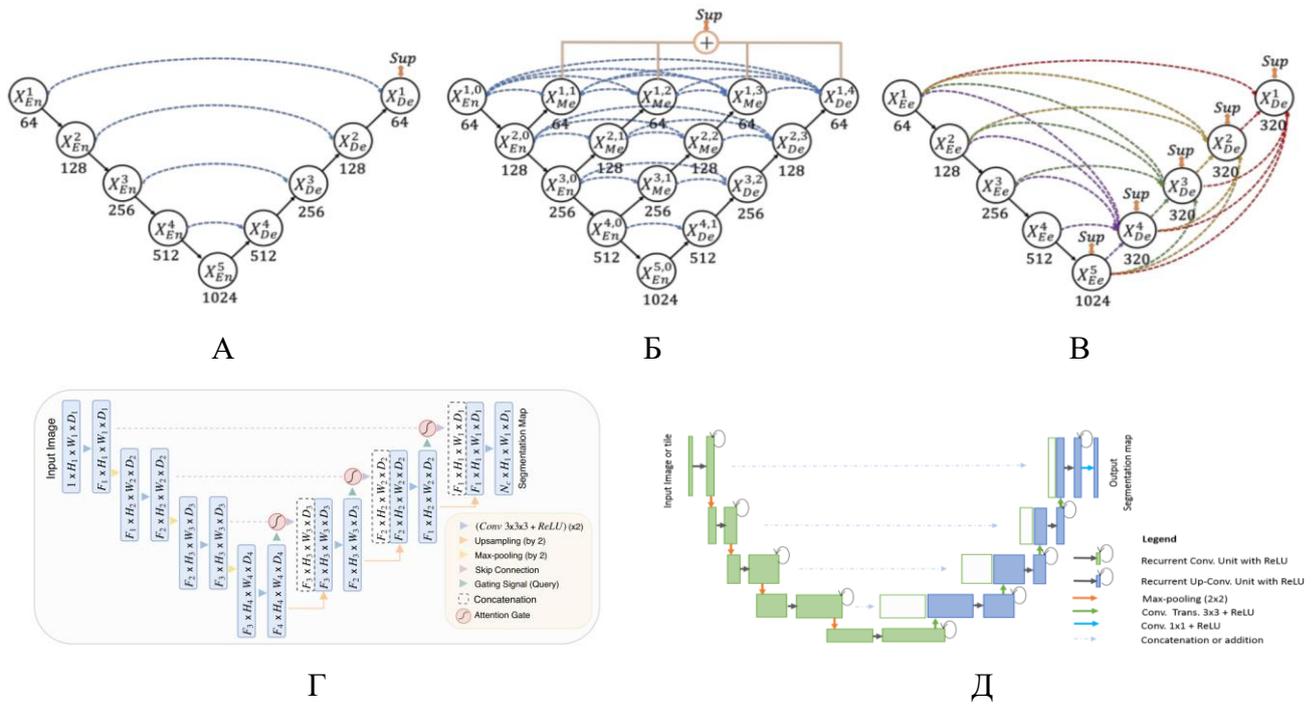


Рисунок 28 – Разновидности сверточных нейронных сетей: А – U-Net; Б – U-Net++; В – UNet 3+; Г – Attention U-Net; Д – R2U-Net [Ronneberger et al., 2015; Zhou et al., 2018; Huang et al., 2020; Oktay et al., 2018; Alom et al., 2018]

Для объективного сравнения архитектур оценивались следующие критерии:

- Точность сегментации – оценивалась с помощью метрик BCE, Accuracy и Intersection over Union (IoU) на тестовой выборке из 100 карт.
- Качественный анализ карт, сравнение выделенных масконов с ранее известными.

Результаты экспериментов выявили существенные различия в качестве сегментации (Таблица 1). Наилучшие показатели получены с применением классической U-Net с предобученными весами VGG-16 (IoU=0.949), что объясняется оптимальным балансом между глубиной сети и сохранением пространственной информации, а также эффективным использованием переноса весов для передачи деталей в декодер. Attention U-Net показала схожие результаты (IoU=0.953), однако ее преимущество оказалось незначительным при существенном увеличении вычислительной сложности. Модели U-Net++ и UNET 3+ продемонстрировали несколько худшие показатели (IoU=0.882 и 0.936 соответственно) из-за склонности к избыточному выделению деталей и шумовых компонентов. Наихудшие результаты показали модели без предобученных весов: U-Net (IoU=0.024) и R2U-Net (IoU=0.862), что доказывает важность использования предобученных весов для данной задачи.

Таблица 1 Сравнение точности сегментации на тестовой выборке для различных моделей СНС

	BCE Loss	Accuracy	IoU
U-Net	0.0027	0.999	0.949
U-Net (без весов)	0.163	0.968	0.024
U-Net++	0.0076	0.997	0.882
UNet 3+	0.0029	0.999	0.936
Attention U-Net	0.0026	0.999	0.953
R2U-Net (без весов)	0.0079	0.997	0.862

Качественный анализ результатов сегментации подтвердил (Таблица 2, Рисунок 29), что базовая U-Net наилучшим образом соответствует требованиям задачи, обеспечивая точное выделение изометричных аномалий без избыточного усложнения модели нейронной сети. Точность оценки определялась путем сравнения с каталогом известных масконов, содержащим 61 маскон, информация о которых получена по литературным данным [Fassett et al., 2012; Liang et al., 2014; Tartèse et al., 2019; Zhao et al., 2021]. Усложненные архитектуры, несмотря на теоретические преимущества, не показали значимого улучшения качества решения, а в случае U-Net 3+ даже привели к появлению артефактов.

Таблица 2 Количество масконов, выделенных с помощью различных видов СНС

Метод выделения изометричных аномалий	TP, верно выделенные масконы	FP, ошибки I рода	FN, ошибки II рода	Precision	Recall	F1-Score
U-Net VGG16	58	25	3	0.699	0.951	0.403
U-Net (без весов)	27	15	34	0.643	0.443	0.262
U-Net++ VGG16	47	10	14	0.825	0.770	0.398
U-Net 3+ VGG16	59	115	2	0.339	0.967	0.251
Attention U-Net VGG16	58	83	3	0.411	0.951	0.287
R2U-Net (без весов)	17	4	44	0.810	0.279	0.207

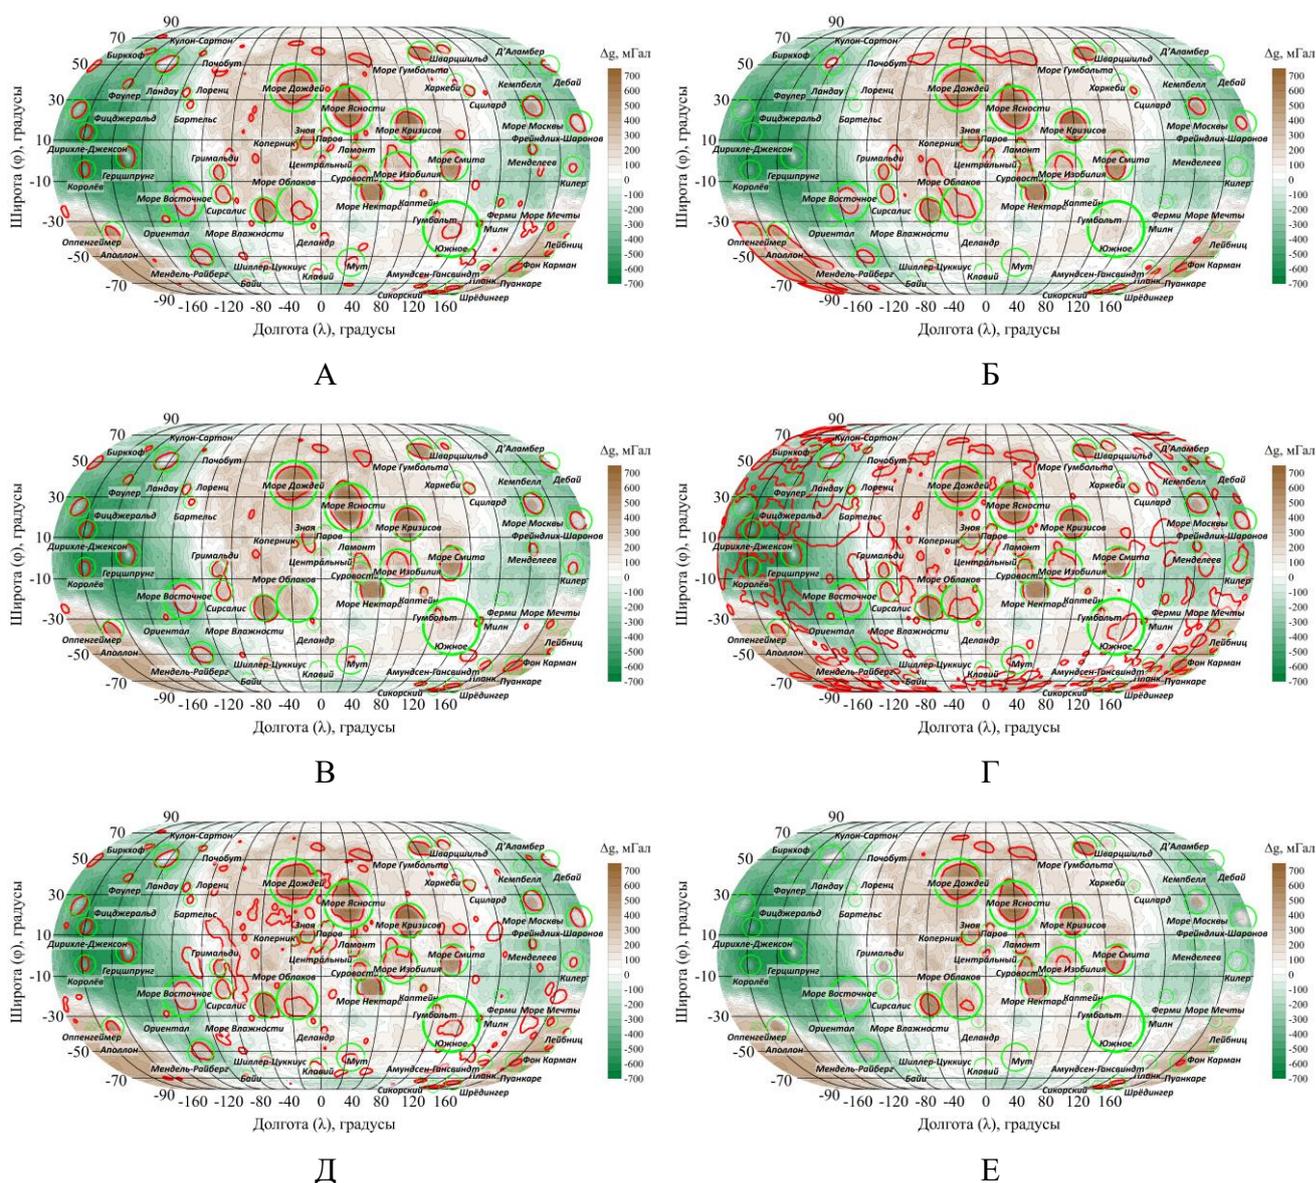


Рисунок 29 – Результаты применения различных архитектур СНС к гравитационному полю Луны (красным цветом) и по литературным данным (зеленым цветом): А – U-Net; Б – U-Net (без весов); В – U-Net++; Г – UNet 3+; Д – Attention U-Net; Е – R2U-Net (без весов)

3.3.2. Сравнительный анализ предобученных энкодеров

По результатам исследования из предыдущего раздела 3.3.1. было выяснено, что использование предобученных весов значительно улучшает точность модели.

В исследовании были протестированы пять широко используемых предобученных весов: классическая VGG-16, три варианта EfficientNet (b0, b2, b4) и ResNet50. Все модели использованы в качестве энкодера сверточной нейронной сети U-Net и дообучены на идентичном наборе синтетических данных.

Качественный анализ результатов показал, что применение весов VGG-16 позволило получить наилучшие результаты по количеству выделенных масконов (58 из 61 масконов), демонстрируя устойчивость к вариациям их размеров (Таблица 3, Рисунок 30).

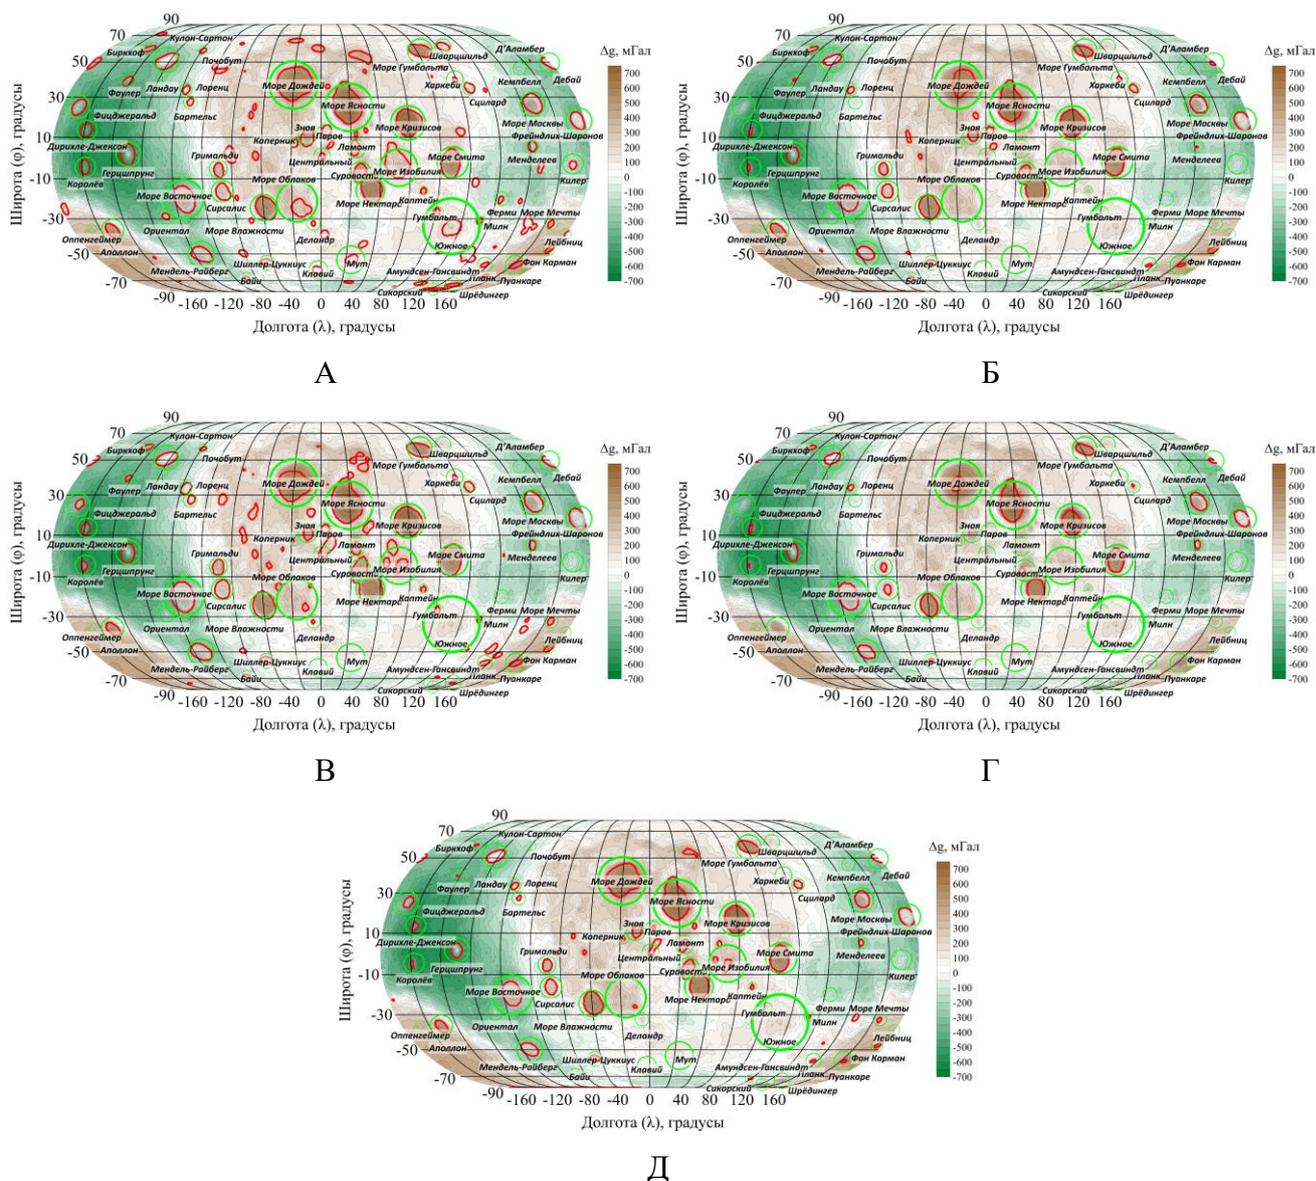


Рисунок 30 – Результаты применения U-Net с различными предобученными архитектурами к гравитационному полю Луны (красным цветом) и по литературным данным (зеленым цветом):

А – VGG-16; Б – EfficientNetb0; В – EfficientNetb2; Г – EfficientNetb2; Д – ResNet50

Таблица 3 Количество масконов, выделенных с помощью СНС U-Net с различными предобученными весами

Метод выделения изометричных аномалий	TP, верно выделенные масконы	FP, ошибки I рода	FN, ошибки II рода	Precision	Recall	F1-Score
U-Net+VGG16	58	25	3	0.699	0.951	0.403
U-Net+EfficientNetb0	33	5	28	0.868	0.541	0.333
U-Net+EfficientNetb2	43	20	18	0.683	0.705	0.347
U-Net+EfficientNetb4	24	1	37	0.960	0.393	0.279
U-Net+ResNet50	42	12	19	0.778	0.689	0.365

3.3.3. Исследование влияния объема обучающей выборки

В задачах глубокого обучения объем и качество обучающих данных являются критически важными факторами, определяющими конечную эффективность модели нейронной сети. Особенность рассматриваемой задачи заключается в необходимости работы с синтетически сгенерированными данными, так как реальные размеченные данные о гравитационных аномалиях Луны крайне ограничены. Это обуславливает необходимость тщательного исследования зависимости качества модели от количества обучающих примеров.

Для проведения исследования разработана серия экспериментов с последовательным увеличением объема обучающей выборки от 50 до 5000 синтетических карт гравитационных аномалий, созданных согласно описанию в разделе 3.1. Ключевые аспекты экспериментальной методики:

1. Все выборки формировались из единого исходного набора с сохранением пропорций различных типов аномалий.
2. Для объективности сравнения при оценке точности использовалась постоянная тестовая выборка (100 карт).
3. Валидационная выборка составляла 10% от обучающего набора для каждого эксперимента.
4. Все эксперименты проводились с одинаковой архитектурой (U-Net с VGG-16 в качестве энкодера) и гиперпараметрами.

Для анализа использовались 3 параметра: метрика качества тестовых данных, скорость обучения и качество прогноза на реальных данных. Для обучения использовался ПК с следующими характеристиками: Intel Core i7-14700KF; DDR4 3600 МГц (18-22-22) 64 Гб; SSD 1000 Гб; GeForce RTX 4060 Ti 8Гб.

В ходе исследования влияния объема обучающей выборки на качество сегментации масконов получены следующие результаты (Таблица 4, 5; Рисунки 31, 32).

Таблица 4 Сравнение точностей сегментации и время обучения на тестовой выборке для различного объема данных

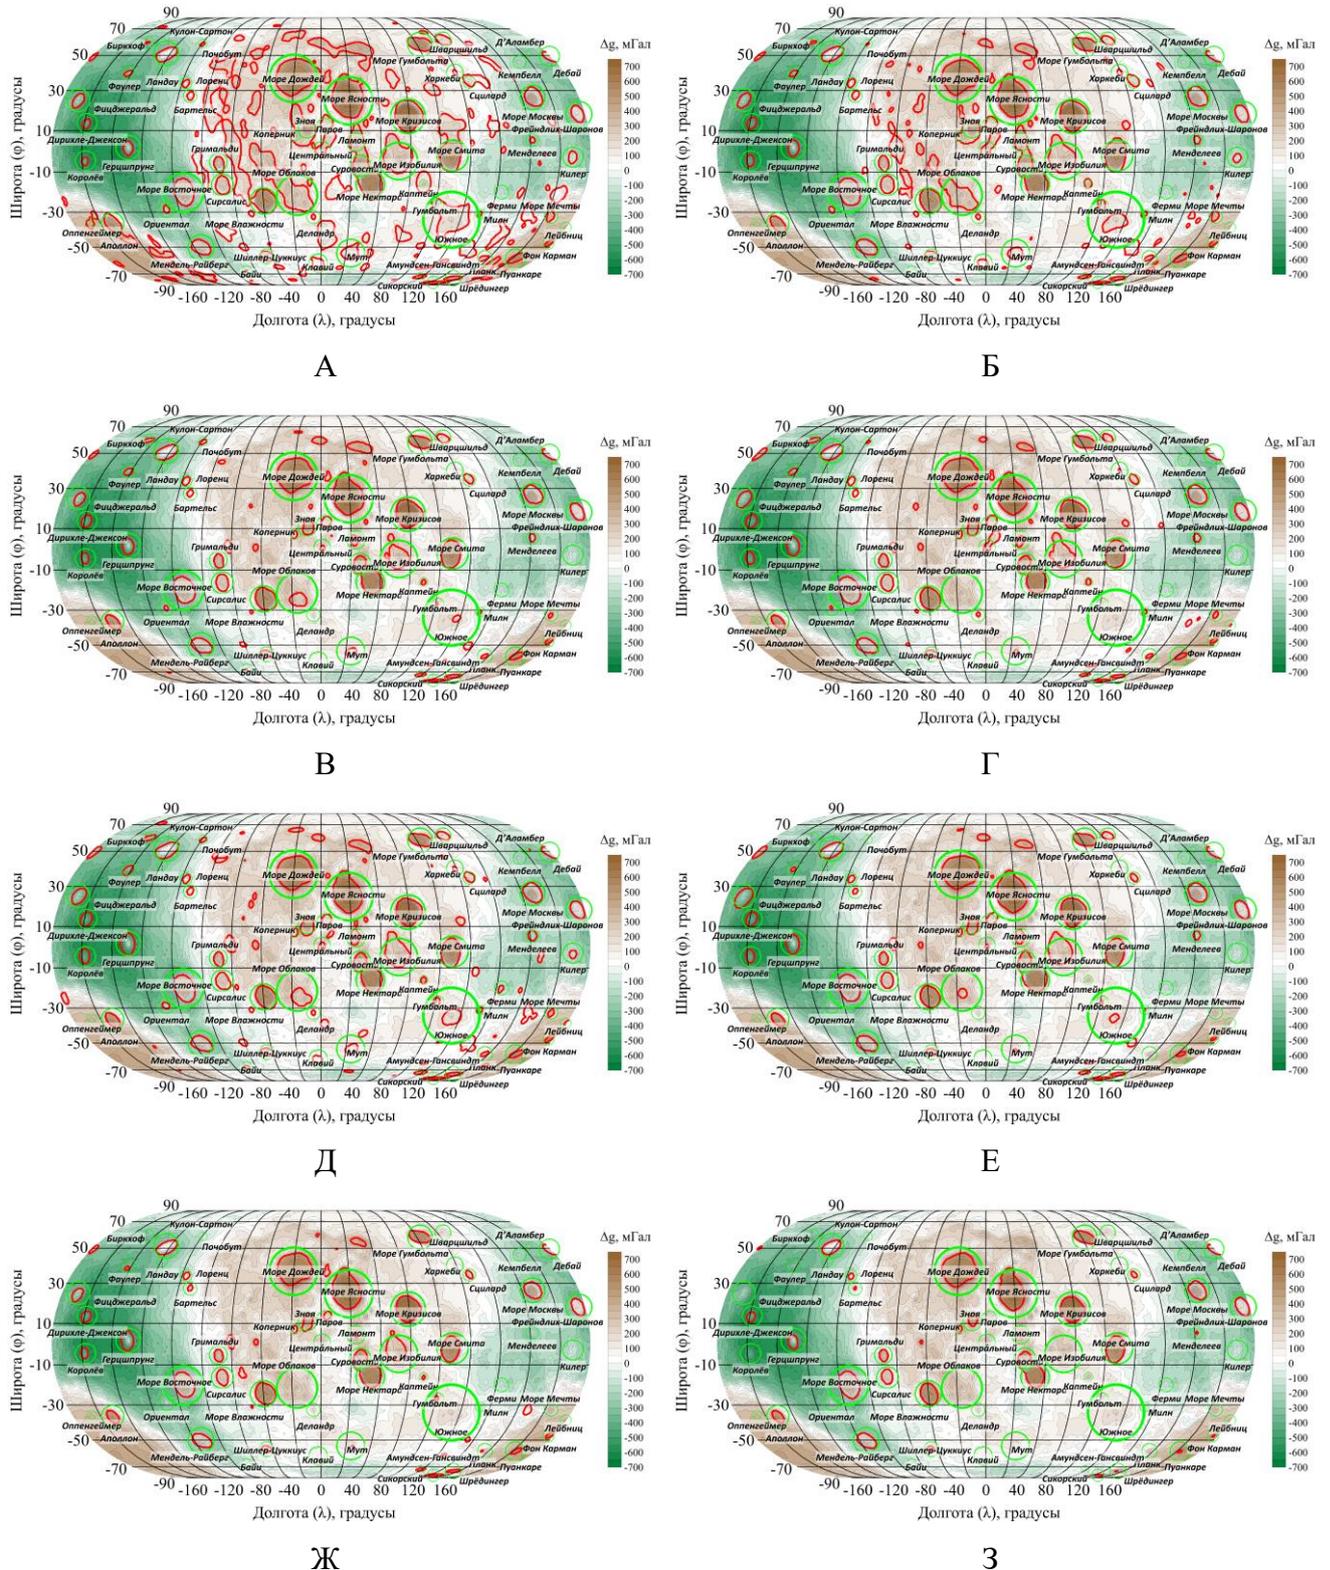
	VCE Loss	Accuracy	IoU	Время обучения, час
50 карт	0.01	0.996	0.846	0.08
100 карт	0.006	0.997	0.891	0.16
200 карт	0.004	0.998	0.934	0.31
300 карт	0.003	0.998	0.941	0.47
500 карт	0.0027	0.999	0.949	0.79
1000 карт	0.002	0.999	0.96	1.57
2000 карт	0.0015	0.999	0.972	3.14
5000 карт	0.0011	0.999	0.98	7.86

Таблица 5 Количество масконов, выделенных с помощью СНС U-Net VGG16 с различным объемом обучающей выборки

Объем обучающей выборки	TP, верно выделенные масконы	FP, ошибки I рода	FN, ошибки II рода	Precision	Recall	F1-Score
50 карт	56	123	5	0.313	0.918	0.233
100 карт	54	52	7	0.509	0.885	0.323
200 карт	51	20	10	0.718	0.836	0.386
300 карт	51	16	10	0.761	0.836	0.398
500 карт	58	25	3	0.699	0.951	0.403
1000 карт	45	8	16	0.849	0.738	0.395
2000 карт	42	10	19	0.808	0.689	0.372
5000 карт	30	1	31	0.968	0.492	0.326

При обучении на малых выборках (50-100 синтетических карт) в выходных масках наблюдалось обилие шумовых артефактов, несмотря на формально высокие метрики (Accuracy=0.996-0.997, IoU=0.85-0.89). Это объясняется недостаточным разнообразием данных, что приводит к переобучению модели на специфические артефакты синтетических карт и снижает её устойчивость к аномалиям в реальных данных. При увеличении объема выборки до 200-1000 карт качество сегментации значительно улучшилось, достигнув лучших значений при 500 картах (IoU=0.949, VCE Loss=0.0027). В этом диапазоне модель демонстрирует наилучший баланс между обобщающей способностью и устойчивостью к шуму, что подтверждается высокой точностью на реальных данных. Однако дальнейшее увеличение объема обучающей выборки до 2000-5000 карт привело к неожиданному эффекту: несмотря на улучшение формальных метрик (IoU до 0.98), на реальных данных стали наблюдаться пропуски масконов. Этот парадокс можно объяснить "переусреднением" признаков из-за избыточного объема

однородных синтетических данных, что снизило чувствительность модели к редким или слабо выраженным аномалиям.



Таким образом, для практического применения в задаче сегментации лунных масконов рекомендуется использовать обучающую выборку объемом 300-500 карт, так как это обеспечивает наилучший компромисс между качеством сегментации, временем обучения и устойчивостью модели.

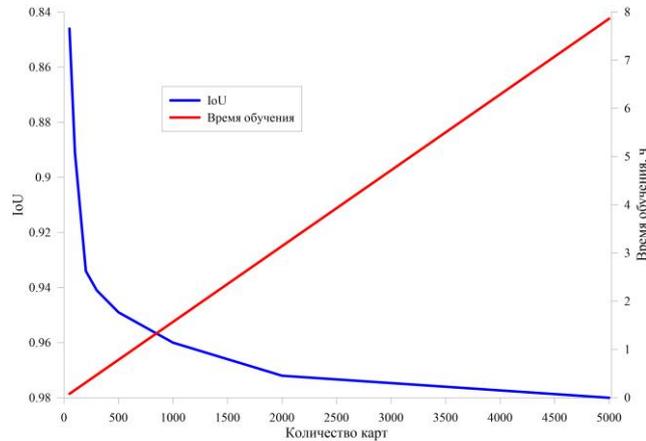


Рисунок 32 – Графики зависимости метрики качества IoU и времени обучения от количества карт

3.3.4. Выбор финальной архитектуры и обоснование

По результатам сравнительного анализа, проведенного в подразделах 3.3.1 и 3.3.2, для решения задачи локализации масконов была выбрана и использована архитектура U-Net с предобученным энкодером VGG-16.

Данное решение обусловлено тем, что классическая U-Net продемонстрировала наилучший баланс между точностью сегментации ($\text{IoU}=0.949$) и вычислительной эффективностью, превзойдя более сложные модификации (Таблица 1). Использование предобученных весов VGG-16 подтверждается плохой сходимостью модели без предобучения ($\text{IoU}=0.024$) и лучшей сходимостью VGG-16 с эталонными данными (58 из 61 масконов, Таблица 3). Прямая последовательная структура VGG-16 наилучшим образом подошла для выделения изометричных аномалий, демонстрируя устойчивость к вариациям их размеров.

Выбранная сеть состоит из двух основных частей: энкодер, который позволяет извлечь необходимые признаки при последовательном уменьшении размерности данных, и декодер, который последовательно возвращает исходную размерность пространственной информации (Рисунок 33).

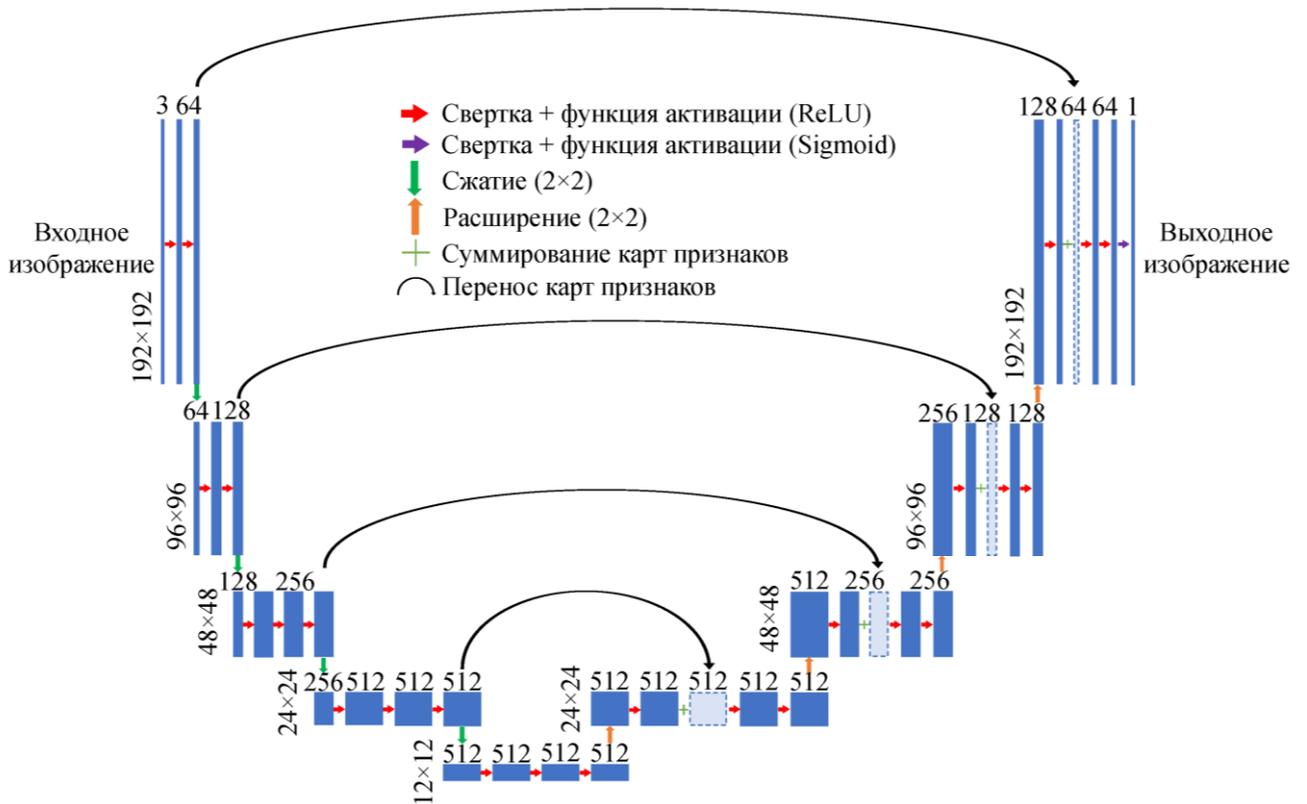


Рисунок 33 – Схема сверточной нейронной сети архитектуры U-Net

Энкодер состоит из нескольких блоков, каждый из которых включает:

- Сверточный слой (Conv2D) с ядром 3×3 и функцией активации ReLU [Glorot et al., 2011].

- Слой объединения (MaxPooling2D) для уменьшения размерности данных.

В результате размерность данных уменьшается, а количество признаков увеличивается.

Декодер обычно симметричен энкодеру и состоит из нескольких блоков, каждый из которых включает:

- Слой расширения (UpSampling2D) для увеличения размерности данных.

- Конкатенацию с соответствующим слоем из энкодера (перенос весов).

- Сверточный слой (Conv2D) с ядром 3×3 и функцией активации ReLU.

Декодер постепенно восстанавливает размерность данных, уменьшая количество признаков вплоть до одного (метка наличия маскона). На выходе сети используется сверточный слой с ядром 1×1 и функцией активации сигмоида, подходящей для классификации бинарных данных [Хайкин, 2006].

В задачах глубокого обучения, особенно при ограниченном объеме данных, использование предобученных моделей служит мощным инструментом для улучшения качества и ускорения обучения (раздел 3.3.1). Помимо VGG [Simonyan, Zisserman, 2015], для энкодера

можно использовать и другие модели, обученные на базе данных ImageNet [Deng et al., 2009], такие как ResNet [He et al., 2016], Inception [Szegedy et al., 2015b], EfficientNet [Tan, Le, 2019] и др. Однако, как показал эксперимент (подраздел 3.3.2), именно VGG-16 показала наилучшие результаты для нашей задачи.

Выбранная сеть VGG-16 (Рисунок 34) состоит из 16 настраиваемых слоев: 13 сверточных и 3 полносвязных, а также 5 слоев объединения, которые последовательно уменьшают размерность изображения вдвое [Simonyan, Zisserman, 2015]. Можно выделить несколько преимуществ использования предобученных весов в нашей задаче:

1. Ранние слои VGG-16 (первые свертки) обучены распознавать универсальные паттерны: границы, текстуры, линии. Эти признаки полезны даже для неродственных задач (например, линейных магнитных аномалий или масконов);
2. Предобученные веса служат хорошей начальной точкой, сокращая время обучения. Модель не начинает "с нуля", а сразу фокусируется на адаптации к поставленной задаче;
3. Использование переноса знаний снижает риск переобучения, особенно если данных мало.

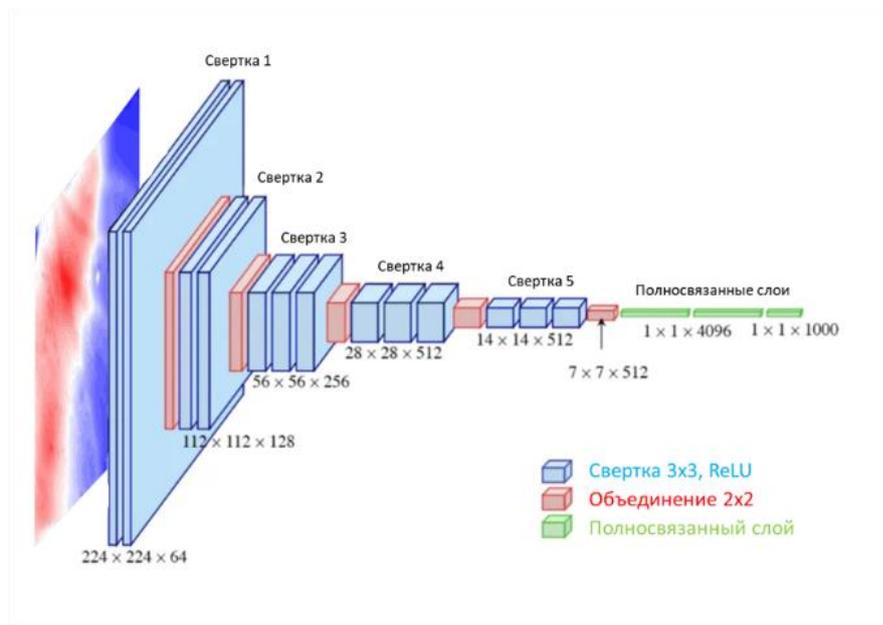


Рисунок 34 – Сверточная нейронная сеть VGG16 (по [Simonyan, Zisserman, 2015] с дополнениями)

Таким образом, для построения итоговой СНС типа U-Net случайные веса энкодера были инициализированы предобученными весами сети VGG-16. На следующем этапе СНС дообучалась на подготовленной синтетической выборке, описанной в разделе 3.1 [Шклярчук, Кузнецов, 2025б]. Комбинация проверенной архитектуры U-Net и предобученного

энкодера VGG-16 была выбрана в качестве эффективной конфигурации для всех последующих задач.

3.3.5. Подбор гиперпараметров для обучения СНС

После выбора финальной архитектуры модели (U-Net с энкодером VGG-16) был проведен этап подбора гиперпараметров обучения. Настройка производилась на синтетической выборке, созданной согласно методике из раздела 3.1, и включала 700 моделей, разделенных на обучающую (500 моделей), валидационную (100 моделей) и тестовую (100 моделей) выборки в соотношении ~70%, 15%, 15% соответственно.

В результате экспериментального подбора были установлены следующие параметры обучения:

- оптимизатор: Adam [Kingma, Ba, 2015];
- скорость обучения (Learning Rate): 0.0001;
- функция потерь (Loss Function): BCE Loss;
- размер пакета данных (Batch Size): 32;
- количество эпох (Epochs): 20.

В качестве ключевой метрики для мониторинга процесса обучения и оценки качества модели использовалась Intersection over Union (IoU). При указанных гиперпараметрах точность обучения нейронной сети, оцененная по метрике IoU на тестовой выборке, составила 0.96. Важно отметить, что такое высокое значение обусловлено рассмотрением синтетического набора данных, идеально соответствующего поставленной задаче. Данная конфигурация была использована для получения всех последующих результатов, включая сравнение с традиционными методами.

3.3.6. Сравнение методов компьютерного зрения и СНС для локализации масконов Луны

Для итоговой оценки эффективности разработанного подхода производительность конфигурации U-Net+VGG-16 была сопоставлена с пятью традиционными алгоритмами компьютерного зрения, применяемых для задач семантической сегментации: адаптивная гауссова бинаризация [Bradley, Roth, 2007], Blob Detection (метод выделения округлых форм) [Lindeberg, 1998], метод Кэнни [Canny, 1986], метод Оцу [Otsu, 1979], метод морфологического градиента [Soille, 2013]. Все методы реализованы с использованием библиотеки OpenCV [Bradski, Kaehler, 2008] и показали различную эффективность при качественном анализе результатов (Таблица 6, Рисунок 35).

Метод Blob Detection на основе лапласиана гауссова фильтра (LoG) продемонстрировал наилучшие результаты среди методов компьютерного зрения (Рисунок 35Б). Этот метод оказался наиболее адаптированным к особенностям задачи благодаря своей способности детектировать округлые структуры, что соответствует природе масконов. Однако качественный анализ выявил и его ограничения – частичные пропуски слабых аномалий и ложные срабатывания.

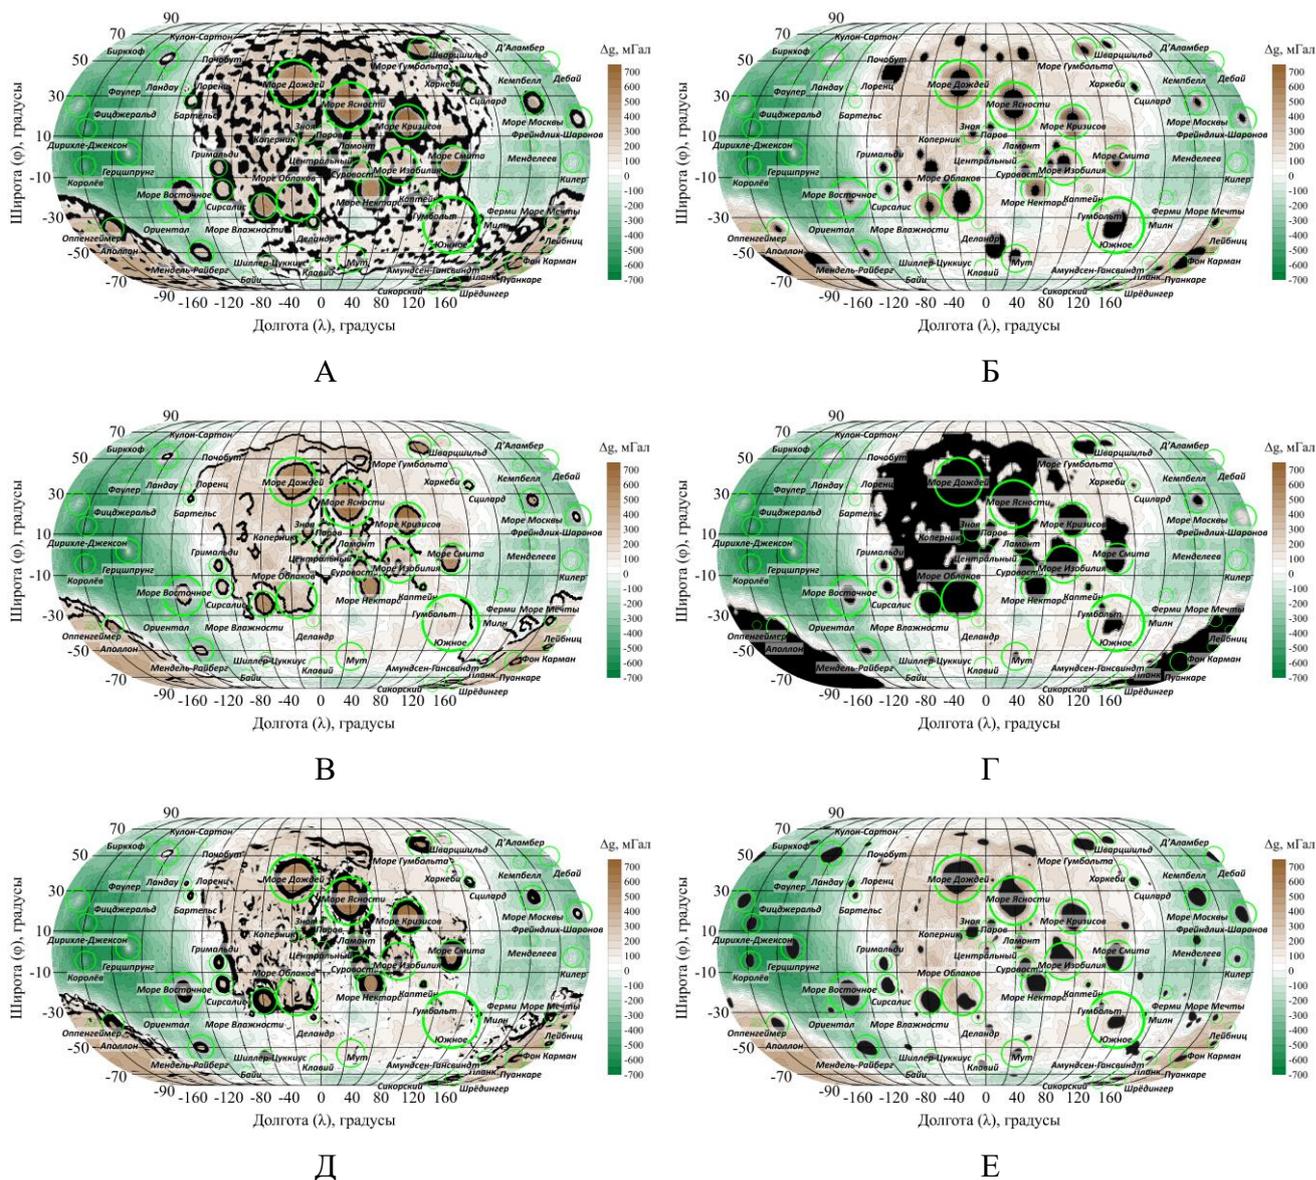


Рисунок 35 – Результат работы методов OpenCV в сравнении с СНС (черным цветом) и по литературным данным (зеленым цветом): А – адаптивная гауссова бинаризация; Б – Blob Detection; В – метод Кэнни; Г – метод Оцу; Д – метод морфологического градиента; Е – сверточная нейронная сеть

Таблица 6 Количество масконов, выделенных с помощью различных алгоритмов компьютерного зрения

Метод выделения изометричных аномалий	TP, верно выделенные масконы	FP, ошибки I рода	FN, ошибки II рода	Precision	Recall	F1-Score
Адаптивная гауссова бинаризация	28	-	33	-	0.459	-
Метод выделения округлых структур	30	18	31	0.625	0.492	0.275
Метод Кэнни	26	25	35	0.510	0.426	0.232
Метод Оцу	15	-	46	-	0.246	-
Метод морфологического градиента	28	18	33	0.609	0.459	0.262
U-Net+VGG16	58	25	3	0.699	0.951	0.403

Алгоритмы, основанные на бинаризации, показали неудовлетворительные результаты. Метод Оцу продемонстрировал ложное выделение соседних структур (Рисунок 35Г), в то время как адаптивная гауссова бинаризация дала фрагментарные результаты с множеством мелких, не относящихся к масконам, областей (Рисунок 35А).

Методы Кэнни (Рисунок 35В) и морфологического градиента (Рисунок 35Д) заняли промежуточные положения. Они смогли выделить контуры масконов, но потребовали сложной постобработки для устранения шума и заполнения пропусков. Особенно проблематичным оказалось выделение слабовыраженных аномалий, которые часто терялись на фоне шумов.

Сравнивая эти результаты с полученными ранее данными по сверточным нейронным сетям, можно сделать однозначный вывод о преимуществе последних (Рисунок 35Е).

Преимущество СНС особенно заметно при работе со слабовыраженными аномалиями, где классические методы либо дают много ложных срабатываний, либо пропускают значительную часть объектов. Это подтверждает целесообразность использования именно нейросетевых подходов для подобных задач анализа гравитационных данных.

3.4. Локализация масконов Луны с использованием СНС и оценка их параметров

Рассмотренная в работе нейронная сеть, обученная на синтетических данных (модельных примерах), применена к аномалиям силы тяжести Луны. Результатом является бинарная маска, где значения 1 означает наличие маскона, а 0 – его отсутствие. Для визуализации и корректной оценки площади отдельных масконов полученная маска спроецирована в равновеликую проекцию Эккерта IV (Рисунок 36).

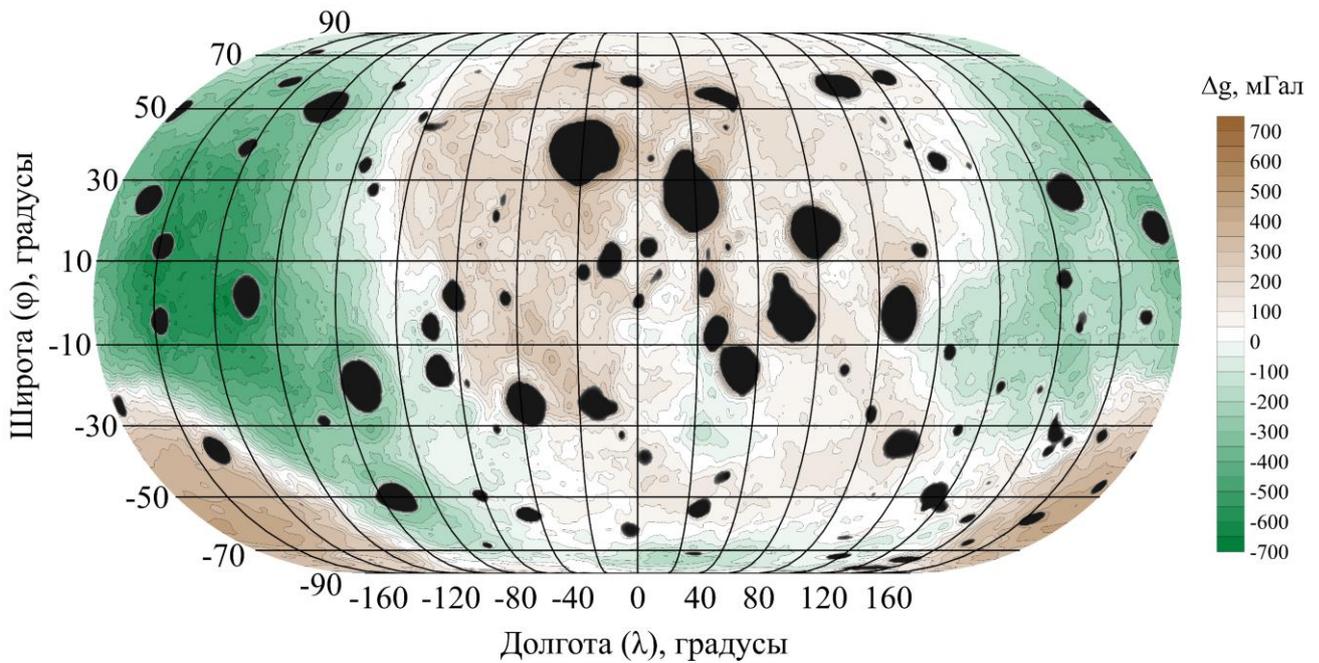


Рисунок 36 – Масконы Луны (черные области) выделенные в аномалиях силы тяжести в редукции Буге с помощью сверточных нейронных сетей

Для оценки точности результатов в качестве эталона рассмотрены масконы, положение которых получено из литературных источников. На текущий момент исследований в гравитационном поле Луны выделено порядка 61 маскона [Fassett et al., 2012; Liang et al., 2014; Tartèse et al., 2019; Zhao et al., 2021]. Их названия, положение центров по селенографическим координатам и диаметр представлены в каталоге (Таблица 7) [Шклярук и др., 2025]. Сопоставляя положение масконов по литературным источникам с аномалиями силы тяжести, можно отметить, что не все они проявлены визуально отличимыми изометричными аномалиями. Исходя из этого, они разделены на 2 группы: проявленные и слабо проявленные в поле (амплитуда менее 200 мГал).

На основе анализа результатов, полученных с использованием обученной СНС, можно отметить следующее: при помощи разработанной методики удалось локализовать 100% (45 из 45) из уже выделенных масконов, явно проявленных в гравитационном поле, и 80% (13 из 16) слабо проявленных масконов.

Для наглядности, полученные результаты представлены на рисунке 37. Предсказанные контуры масконов выделены красным цветом. Выделенные с помощью сверточной нейронной сети масконы меньше в размерах в среднем на 50-200 километров. Предположительно, это связано с тем, что диаметры масконов в работах [Fassett et al., 2012; Liang et al., 2014; Tartèse et al., 2019; Zhao et al., 2021] оценены по приуроченным к ним кратерам на поверхности Луны, а не по аномальному гравитационному полю.

Таблица 7 Каталог масконов Луны [Шклярук и др., 2025]

№	Название	Название на английском	Долгота, град	Широта, град	Диаметр, км	
					По литературным данным	По результатам СНС
Проявленные в поле						
1	Море Ясности	Serenitatis	199.18	24.76	850	588
2	Море Дождей	Imbrium	159.84	36.49	850	590
3	Море Восточное	Orientale	85.70	-20.07	700	382
4	Море Кризисов	Crisium	239.10	17.00	610	438
5	Море Смита	Smythii	267.80	-2.06	550	430
6	Море Нектара	Nectaris	213.39	-15.98	500	404
7	Море Влажности	Humorum	140.04	-24.24	460	351
8	Фрейндлих-Шаронов	Freundlich-Sharonov	355.70	18.00	455	348
9	Мендель-Райберг	Mendel-Rydberg	85.34	-50.08	450	278
10	Герцшпрунг	Hertzprung	51.07	1.86	430	285
11	Море Москвы	Moscoviense	327.54	26.37	430	313
12	Море Гумбольта	Humboldtianum	262.52	57.31	430	282
13	Кулон-Сартон	Coulomb-Sarton	56.84	51.32	430	300
14	Фицджеральд	Fitzgerald-Jackson	11.47	25.04	400	334
15	Аполлон	Apollo	28.60	-36.14	390	248
16	Сирсалис	Cruger-Sirsalis	112.96	-16.16	380	251
17	Суровости	Asperitatis	206.01	-7.01	380	271
18	Королев	Korolev	22.30	-4.44	350	187
19	Килер	Keeler	348.35	-2.78	350	127
20	-	Debye (Топо22)	359.12	49.43	350	200
21	Пуанкаре	Poincaré	342.70	-57.67	346	151
22	Дирихле-Джексон	Dirichlet-Jackson	21.86	13.59	340	223
23	Ламонт	Lamont	203.26	4.53	320	308
24	Зноя	Aestuum	170.68	10.83	317	410
25	Гримальди	Grimaldi	111.18	-5.24	310	185
26	Центральный	Medii	180.62	0.89	287	107
27	Ориентал	Orientale SW	71.14	-28.59	280	102
28	Шварцшильд	Compton-Dugan (Schwarzschild)	284.94	60.72	270	190
29	Шредингер	Schrödinger	313.80	-74.70	269	121
30	Планк	Planck	316.60	-57.22	260	87
31	Шиллер-Цуккиус	Schiller-Zucchius	135.00	-56.00	260	162
32	Паров	Vaporum	182.22	12.52	242	199
33	Ферми	Fermi	303.59	-19.82	241	45
34	Море Мечты	Ingenii	344.05	-32.38	231	84
35	Бартельс	Bartels-V.	88.36	27.26	230	115

№	Название	Название на английском	Долгота, град	Широта, град	Диаметр, км	
					По литературным данным	По результатам СНС
36	Деландр	Deslandres	174.43	-32.55	227	64
37	Фаулер	Fowler-Charlier	37.75	39.60	225	263
38	Менделеев	Mendeleev	321.17	5.38	216	149
39	Сцилард	Szillard	286.73	34.44	210	258
40	-	Amundsen-Ganswindt	304.88	-80.85	210	115
41	Лоренц	Lorentz	82.86	34.09	200	110
42	Коперник	Copernicus	162.24	7.28	170	146
43	Милн	Milne	292.78	-31.00	163	93
44	Байи	Bailly	111.63	-67.04	160	32
45	Каптейн	Palmer-Kapteyn	249.51	-15.88	150	95
Слабо проявленные в поле						
46	Южное	Australe	273.63	-33.99	997	444
47	Море Облаков	Nubium	163.40	-21.30	715	394
48	Море Изобилия	Fecunditatis	232.02	-4.66	660	497
49	Мут	Mutus-Vlaq	204.04	-53.73	490	262
50	Клавий	Clavius	177.49	-60.90	320	202
51	Харкеби	Harkhebi	278.84	39.82	290	39
52	Кемпбелл	Campbell	332.12	45.92	222	-
53	Биркхоф	Birkhoff	33.22	58.96	200	93
54	Гумбольт	Humboldt	261.53	-26.72	199	162
55	Фон Карман	Von Kármán	356.07	-47.63	186	95
56	Лейбниц	Leibnitz	359.35	-38.23	180	45
57	Ландау	Landau	61.19	41.73	180	-
58	Оппенгеймер	Oppenheimer	14.13	-35.25	150	-
59	Почобут	Poczobutt	80.90	57.72	150	123
60	Сикорский	Sikorsky	278.21	-73.01	130	115
61	Д'Аламбер	D'Alembert	344.88	51.07	110	106

Важным результатом исследования стала локализация более 20 новых областей, не описанных в литературе, которые могут быть отнесены к масконам благодаря анализу гравитационного поля Луны с помощью сверточной нейронной сети. Их природа и свойства станут объектом дальнейшего исследования. Для подтверждения выделенных масконов рассмотрена высокочастотная составляющая аномального гравитационного поля (Фильтр высоких частот (ФВЧ) с периодом среза 500 км) (Рисунок 38). Видно, что области, невыделенные в литературных источниках, но выделенные с помощью СНС, относятся к положительным изометричным высокочастотным гравитационным аномалиям.

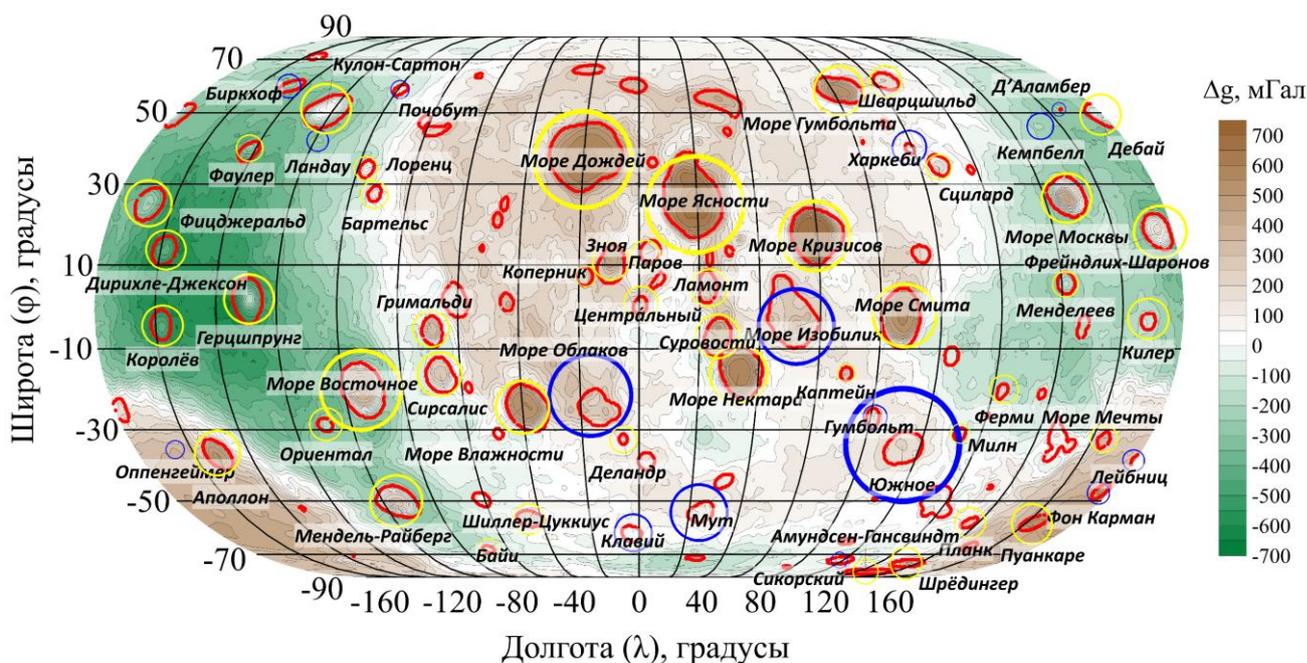


Рисунок 37 – Аномалии поля силы тяжести Луны в редукции Буге с контурами масконов, локализованными с помощью сверточных нейронных сетей (красные контуры) и по литературным данным (желтым цветом – явно проявленные; синим цветом – слабо проявленные)

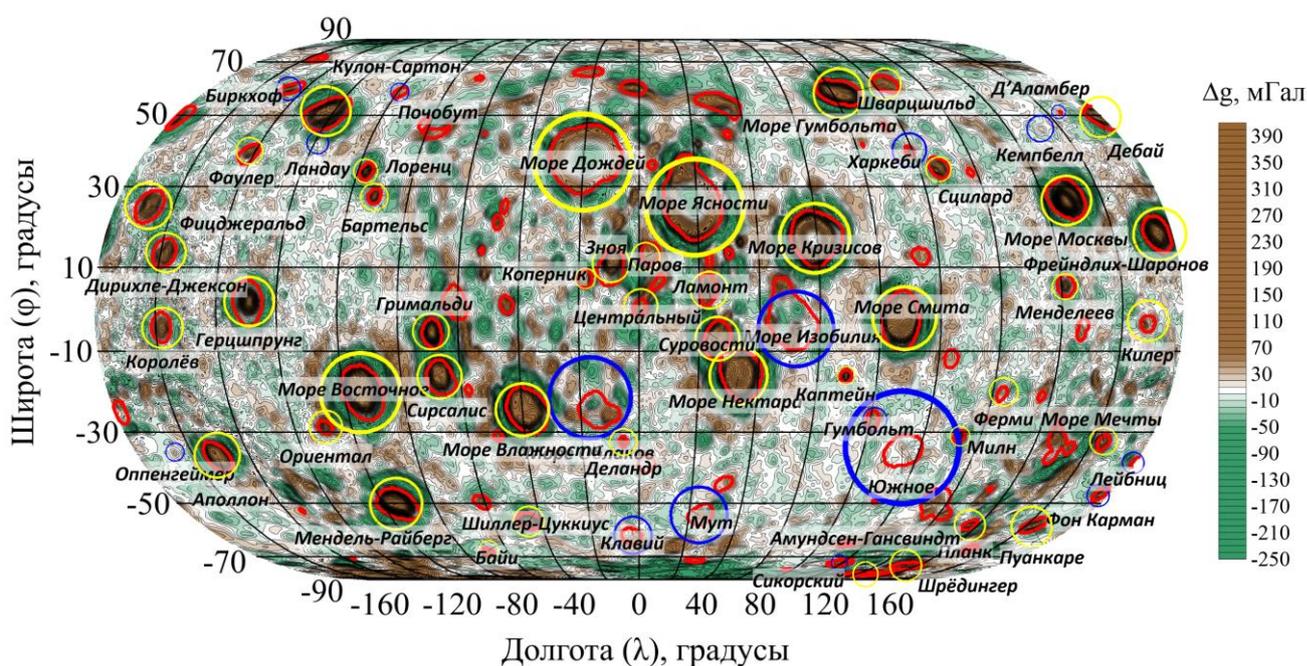


Рисунок 38 – Высоочастотная составляющая поля силы тяжести Луны (ФВЧ – 500 км) с контурами масконов, локализованными с помощью сверточных нейронных сетей (красные контуры) и по литературным данным (желтым цветом – явно проявленные; синим цветом – слабо проявленные)

Для дополнительного подтверждения схожести новых областей с выделенными литературными масконами, произведено сравнение графиков аномалий 3-х новых масконов, выделенных с помощью СНС и маскона Менделеева (Рисунок 39, 40). Маскон Менделеев – положительная аномалия силы тяжести (Рисунок 40Г). Гравитационные аномалии от 3-х новых масконов, выделенных СНС (Рисунок 40А-В), аналогичны по форме с масконом Менделеев и другими, описанными в литературе [Fassett et al., 2012; Liang et al., 2014; Tartèse et al., 2019; Zhao et al., 2021]. В связи с этим, можно сделать вывод о том, что выделенные с помощью СНС изометричные аномалии можно отнести к масконам.

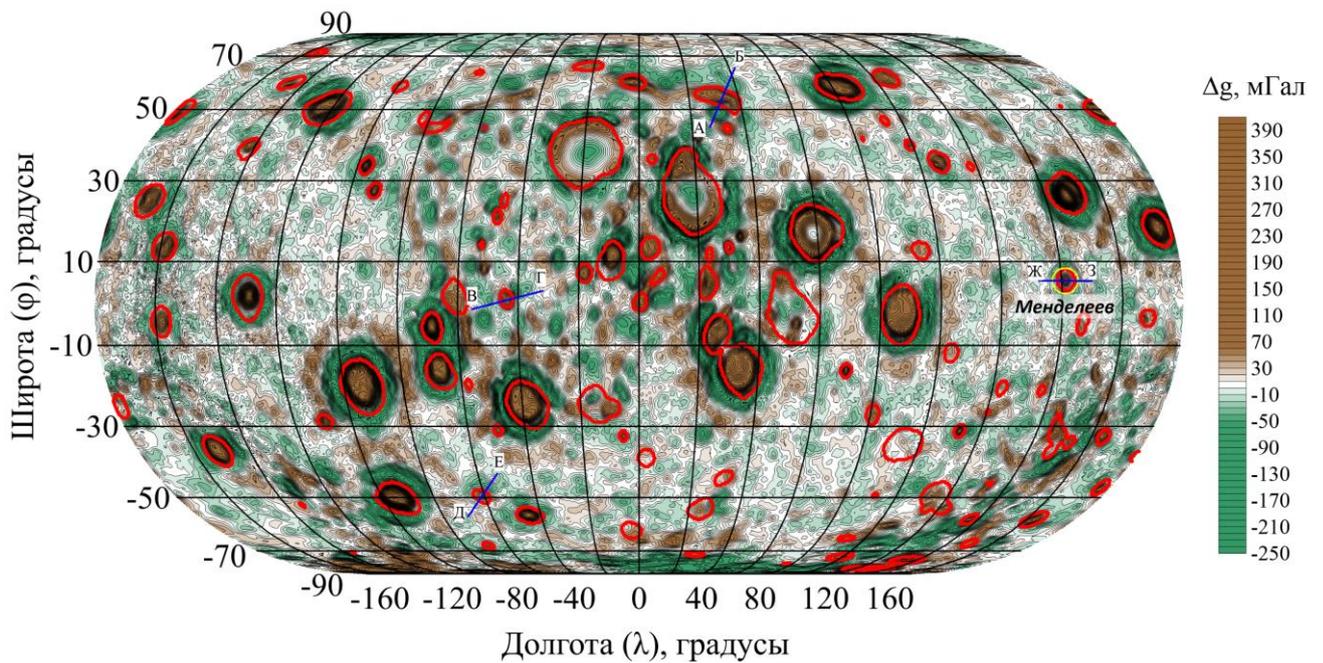


Рисунок 39 – Высоочастотная составляющая поля силы тяжести Луны (ФВЧ – 500 км) с контурами масконов, локализованными с помощью сверточных нейронных сетей (красные контуры) и нанесенными профилями через аномалии

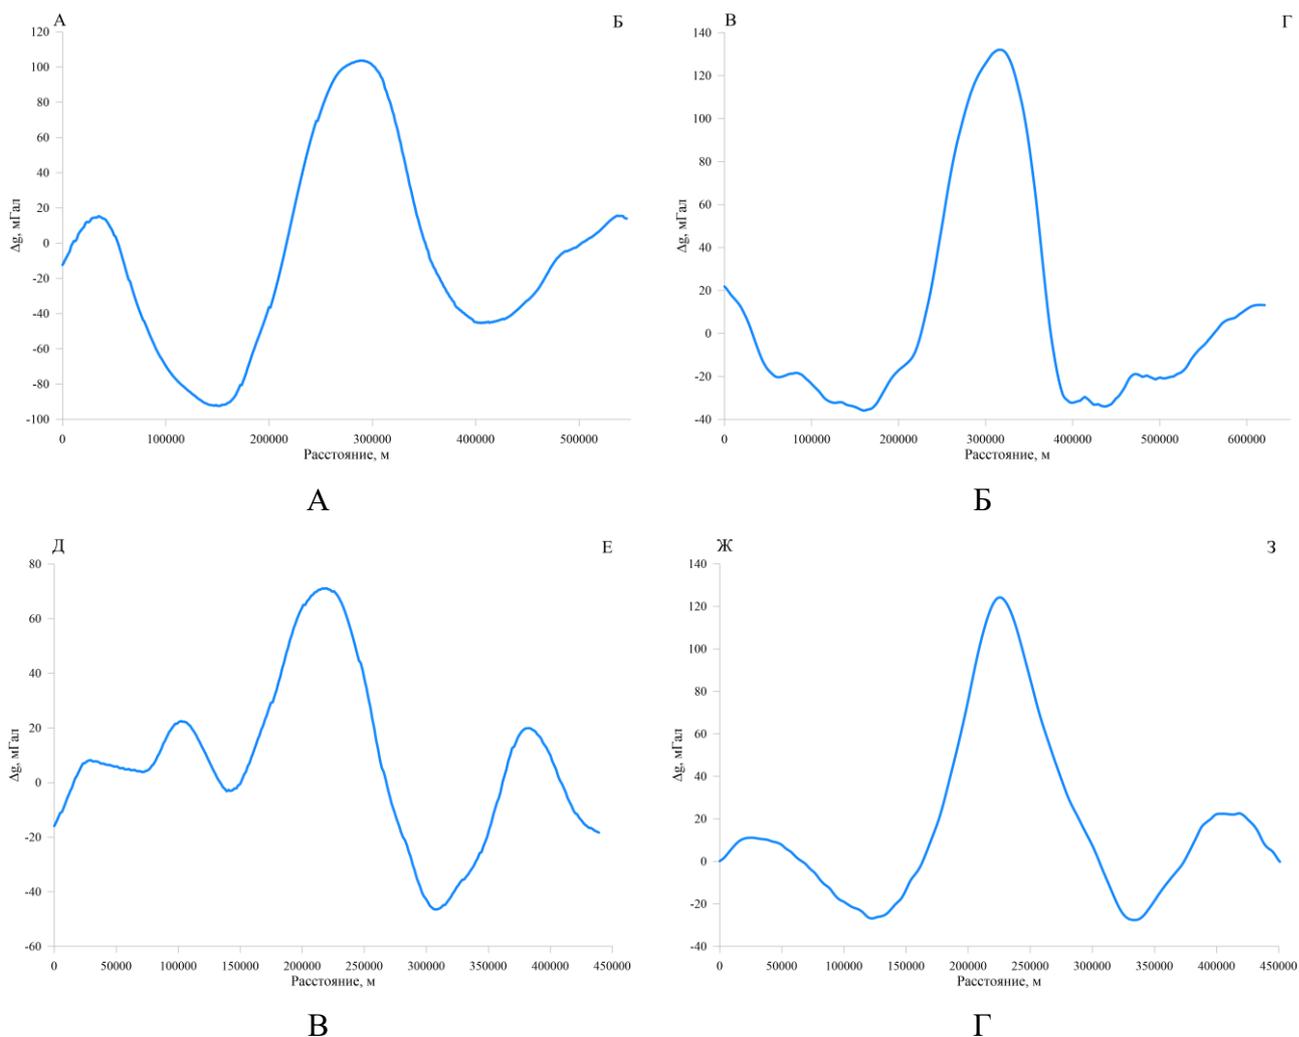


Рисунок 40 – Графики аномалий масконов: А – профиль А-Б; Б – профиль В-Г; В – профиль Д-Е; Г – профиль Ж-З (маскон Менделеев)

3.5. Выводы по Главе 3

В данном разделе диссертационной работы разработан и успешно применен метод локализации масконов Луны на основе сверточных нейронных сетей. Основным результатом стало создание синтетической обучающей выборки, моделирующей гравитационные эффекты масконов, а также фоновые и локальные компоненты поля, что позволило компенсировать отсутствие реальных размеченных данных. В ходе исследования установлено, что архитектура U-Net с предобученными весами VGG-16 демонстрирует наилучшие результаты для задачи выделения изометричных аномалий, достигая точности по метрике IoU = 0.96 на синтетических данных.

Важным выводом также стало подтверждение роли предобученных весов для эффективного обучения модели нейронной сети. Эксперименты показали, что использование случайной инициализации весов приводит к резкому снижению качества сегментации, в то время

как предобученные на ImageNet веса VGG-16 обеспечивают устойчивую работу даже при ограниченном объеме данных.

Практическое применение предложенного метода позволило локализовать 100% известных масконов, явно проявленных в гравитационном поле, и 80% слабо проявленных, а также выявить более 20 новых потенциальных областей, которые могут быть отнесены к масконам. Эффективный объем обучающей выборки составил 300-500 синтетических карт, что обеспечило баланс между точностью сегментации и вычислительными затратами. Сравнение с классическими методами компьютерного зрения (такими как Blob Detection, бинаризация Оцу, детектор Кэнни и др.) подтвердило значительное преимущество СНС, особенно в задачах выделения слабовыраженных аномалий.

Полученные результаты открывают перспективы для дальнейших исследований, включая уточнение природы вновь выявленных аномалий, адаптацию метода для анализа гравитационных полей других небесных тел, а также расширение обучающей выборки за счет комбинации синтетических и реальных данных. Таким образом, применение сверточных нейронных сетей доказало свою эффективность в решении задач геофизического анализа и может быть использовано для автоматизации обработки гравитационных и магнитных полей в будущих исследованиях.

Глава 4. Выделение осей линейных аномалий в гравитационных и магнитных полях на основе сверточных нейронных сетей²

Гравиразведка и магниторазведка эффективны при картировании линейно вытянутых структур благодаря возможности обеспечить качественную площадную характеристику района исследования. При этом их выделение зачастую осложнено наложением локальных аномалий различной природы. В настоящее время составление схем линейных аномалий, приуроченных к разломным зонам, дайковым комплексам и т.п., во многих случаях сводится на первом этапе к поиску наиболее информативных трансформант с подходящими ядрами преобразования (например, высокочастотная фильтрация, вычисление полного горизонтального градиента и т.п.), и на втором этапе – ручной экспертной интерпретации.

Не уменьшая общности подхода, в работе рассматривается задача выделения линейных аномалий геофизических полей. В первую очередь речь идет об аномалиях магнитного поля, связанных с протяженными магматическими комплексами (дайками), разломными зонами и техногенными объектами. Также, как и в Главе 3 поставленная задача решается с применением сверточных нейронных сетей.

4.1. Методика создания синтетической обучающей выборки для выделения линейных аномалий в магнитном поле

Для выбора архитектуры сверточной нейронной сети и определения весов её нейронов, получаемых в ходе обучения, необходимо подготовить обучающую выборку. В ходе данной работы она составлена из примеров, которые включают пары входных (магнитное поле) и выходных (положение линеаментов) матриц. Обучающая выборка, может быть, как собрана на основе размеченных реальных примеров данных, так и создана синтетическим путем. При этом важно, чтобы она была репрезентативной и включала достаточное количество примеров для эффективного обучения. Обучающая выборка может достигать нескольких сотен, а порой и тысяч отдельных примеров. Одной из сложностей при использовании машинного обучения в целом, и нейронных сетей в частности для решения задач интерпретации гравитационных и магнитных полей является затрудненный поиск и подготовка необходимого большого

² При подготовке данного раздела диссертации использована следующая публикация, выполненная автором в соавторстве, в которой, согласно Положению о присуждении ученых степеней в МГУ, отражены основные результаты, положения и выводы исследования:

количества реальных проинтерпретированных (размеченных) данных. Поэтому в работе массив данных создан синтетическим путем, как и в Главе 3.

В качестве модели аномального магнитного поля ΔT линейно вытянутого источника рассмотрен эффект прямоугольной призмы, геометрические параметры которой близки к модели дайки [Булычев и др., 2019]:

$$\Delta T = \sqrt{(T_{0X} + X)^2 + (T_{0Y} + Y)^2 + (T_{0Z} + Z)^2} - T_0, \quad (17)$$

где X, Y, Z – компоненты аномального магнитного поля, T_0 – нормальное магнитное поле, а T_{0X}, T_{0Y}, T_{0Z} – соответствующие его компоненты. В рамках данной работы рассмотрены только вертикально намагниченные прямоугольные призмы, компоненты магнитного эффекта которых можно записать [Plouff, 1976]:

$$\begin{aligned} X &= J_z \ln(r + \eta_i) \left| \begin{array}{c} \xi_2 \\ \xi_1 \end{array} \right| \left| \begin{array}{c} \eta_2 \\ \eta_1 \end{array} \right| \left| \begin{array}{c} \zeta_2 \\ \zeta_1 \end{array} \right|; \\ Y &= J_z \ln(r + \xi_i) \left| \begin{array}{c} \xi_2 \\ \xi_1 \end{array} \right| \left| \begin{array}{c} \eta_2 \\ \eta_1 \end{array} \right| \left| \begin{array}{c} \zeta_2 \\ \zeta_1 \end{array} \right|; \\ Z &= -J_z \arctg \frac{\xi_i * \eta_i}{\zeta_i * r} \left| \begin{array}{c} \xi_2 \\ \xi_1 \end{array} \right| \left| \begin{array}{c} \eta_2 \\ \eta_1 \end{array} \right| \left| \begin{array}{c} \zeta_2 \\ \zeta_1 \end{array} \right|, \end{aligned} \quad (18)$$

где J_z – намагниченность призмы, ξ_i, η_i, ζ_i – координаты границ призмы по осям O_x, O_y и O_z соответственно в предположении, что точка расчета расположена в начале системы координат, а r – расстояние от точки расчета до угла призмы с координатами ξ_i, η_i, ζ_i .

Для расчета формируется область размером 192×192 ячейки, что при масштабе, например, 1:10 000, соответствует области порядка 20×20 км. Важно отметить, что размер ячеек матрицы не является параметром, участвующим в обучении и дальнейшем применении нейронной сети. Количество ячеек выбрано исходя из архитектуры нейронной сети, используемой в работе, обусловленной скоростью обучения и возможностями персонального компьютера (см. раздел 3.3).

Алгоритм создания обучающей выборки состоит из следующих этапов:

1. Случайным образом задаются положение и геометрические параметры призмы, а именно ширина, длина, высота и угол поворота, а также намагниченность и параметры нормального поля. Пределы изменчивости параметров подобраны таким образом, чтобы вычисляемые аномалии магнитного поля были подобны реально зафиксированным.

2. Вычисляется магнитный эффект полученных призм в точках матрицы размером 192×192 ячеек (Рисунок 41А).

3. Создается матрица, характеризующая положение осей линеаментов. Вдоль этой оси создается линия шириной в 3 пикселя, в пределах которой ячейкам матрицы присваивается значение 1. Остальные ячейки матрицы – 0 (Рисунок 41Б).

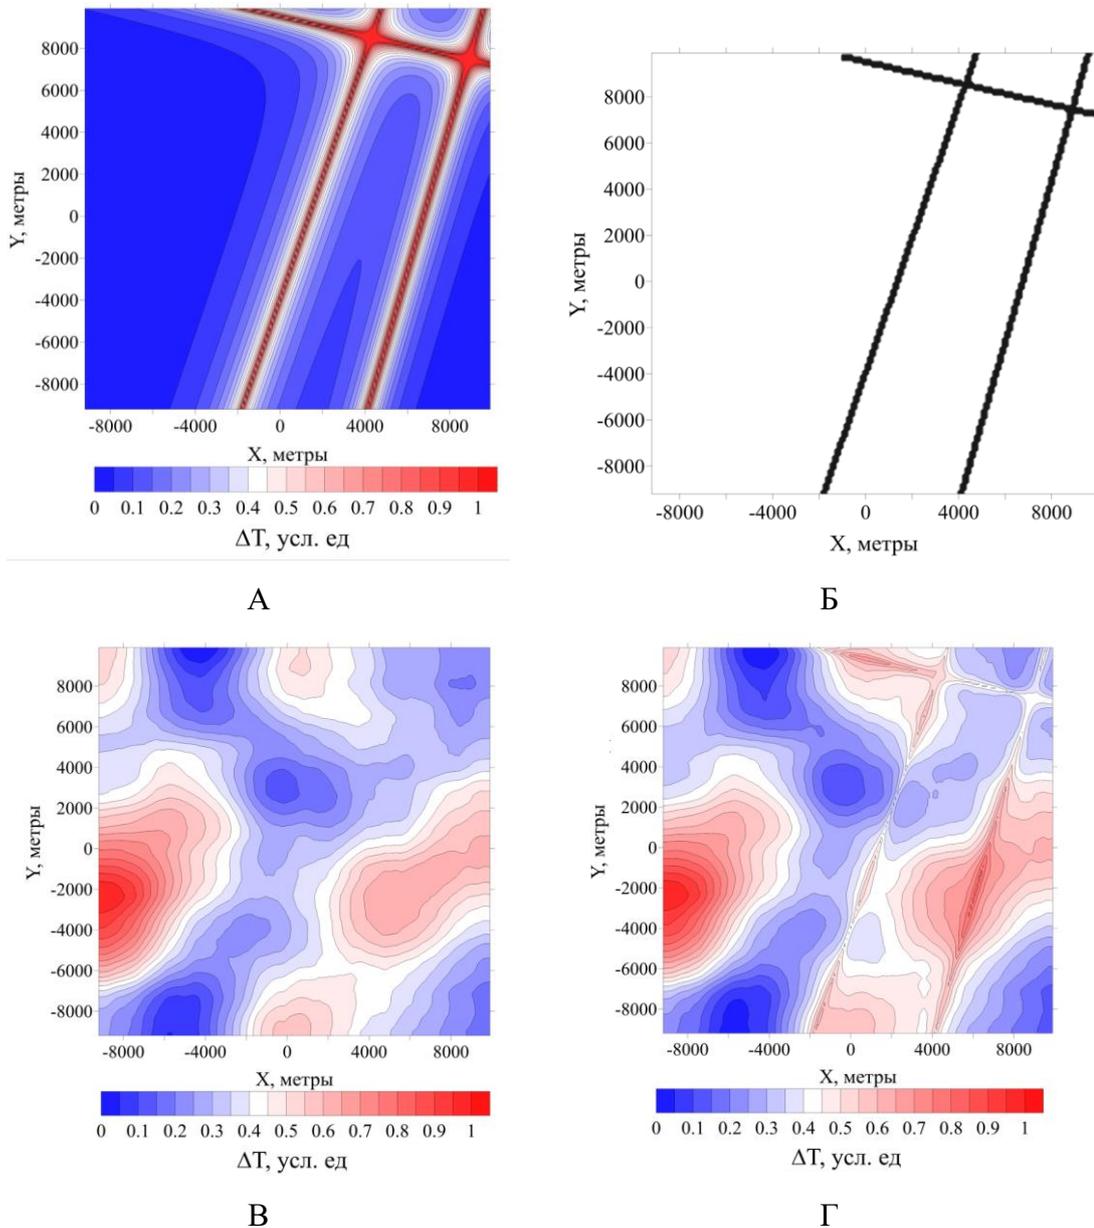


Рисунок 41 – Пример модели из обучающей выборки: А – магнитный эффект линейно вытянутой призмы; Б – положение линеамента, используемое для обучения СНС; В – случайный шум; Г – итоговая модель для обучения СНС

4. Создается матрица со значениями искусственной помехи (шума): для каждой ячейки вычисляется случайно значение из диапазона 10-50% от амплитуды рассчитанного поля. Поскольку синтетические модели должны характеризовать реально существующие поля,

характеризующиеся гладкой формой, то полученная матрица сглаживается фильтром осреднения в скользящем окне размером 30×30 ячеек (Рисунок 41В).

5. Полученный магнитный эффект призмы и шума суммируются (Рисунок 41Г).

Для эффективного обучения нейронной сети входные данные (аномальное магнитное поле) необходимо нормализовать и привести к размерности выходных данных (матрицы, характеризующей положение линеамента). Это особенно важно при работе с большими объемами данных, где каждый элемент может иметь различный диапазон значений. Полученная матрица магнитного поля нормализуется и приводится к диапазону от 0 до 1.

В результате каждый пример из обучающей выборки включает две матрицы: магнитное поле и положение линейной структуры. Для повышения реалистичности синтетических данных на каждой генерируемой карте случайным образом размещается от 1 до 10 линейных объектов.

Для обучения нейронной сети создан массив из 500 наборов полей и положения линеаментов.

4.2. Создание модели СНС и её апробация на модельном примере

Модель для выделения линейных аномалий выбрана по аналогии с главой 3 – U-Net с предобученными весами VGG-16. Для решения задачи выделения линейных аномалий потенциальных полей были выбраны следующие параметры обучения: оптимизатор – Adam, скорость обучения – 0.0001, количество эпох – 50, размер пакета – 25.

Выбор метрик оценки качества – F1-Score и Mean Squared Error (MSE). В отличие от сегментации изометричных аномалий, где важна точность совпадения площадных контуров (IoU), при выделении осей линеаментов ключевыми становятся две характеристики: сбалансированная оценка точности и полноты предсказаний (что эффективнее показывает метрика F1-score) и резкость границ предсказаний. Метрика MSE, чувствительная к отклонениям предсказанных вероятностей от целевых значений 0 и 1, выступает индикатором формирования сетью «четких», не размытых выходов, что принципиально важно для последующего применения алгоритмов скелетизации и получения однопиксельных линий.

На синтетических примерах по метрике F1-Score получено значение – 0.973, по MSE – 0.003, что свидетельствует о высоком общем качестве классификации и резкости выходных данных. Для оценки точности работы нейронной сети создана валидационная выборка из модельных примеров, которые не входили ни в обучающую, ни в тестовую выборки. Данная выборка состоит из 100 примеров, на которых количество линейных аномалий на одной карте варьировалось от 6 до 10. На синтетических примерах с большим количеством линеаментов (от 6 до 10), сверточная нейронная сеть работает с точностью 0.92 по метрике F1-score (Рисунок 42).

Основные ошибки возникают на пересечениях линейаментов и на краях моделей аномального магнитного поля.

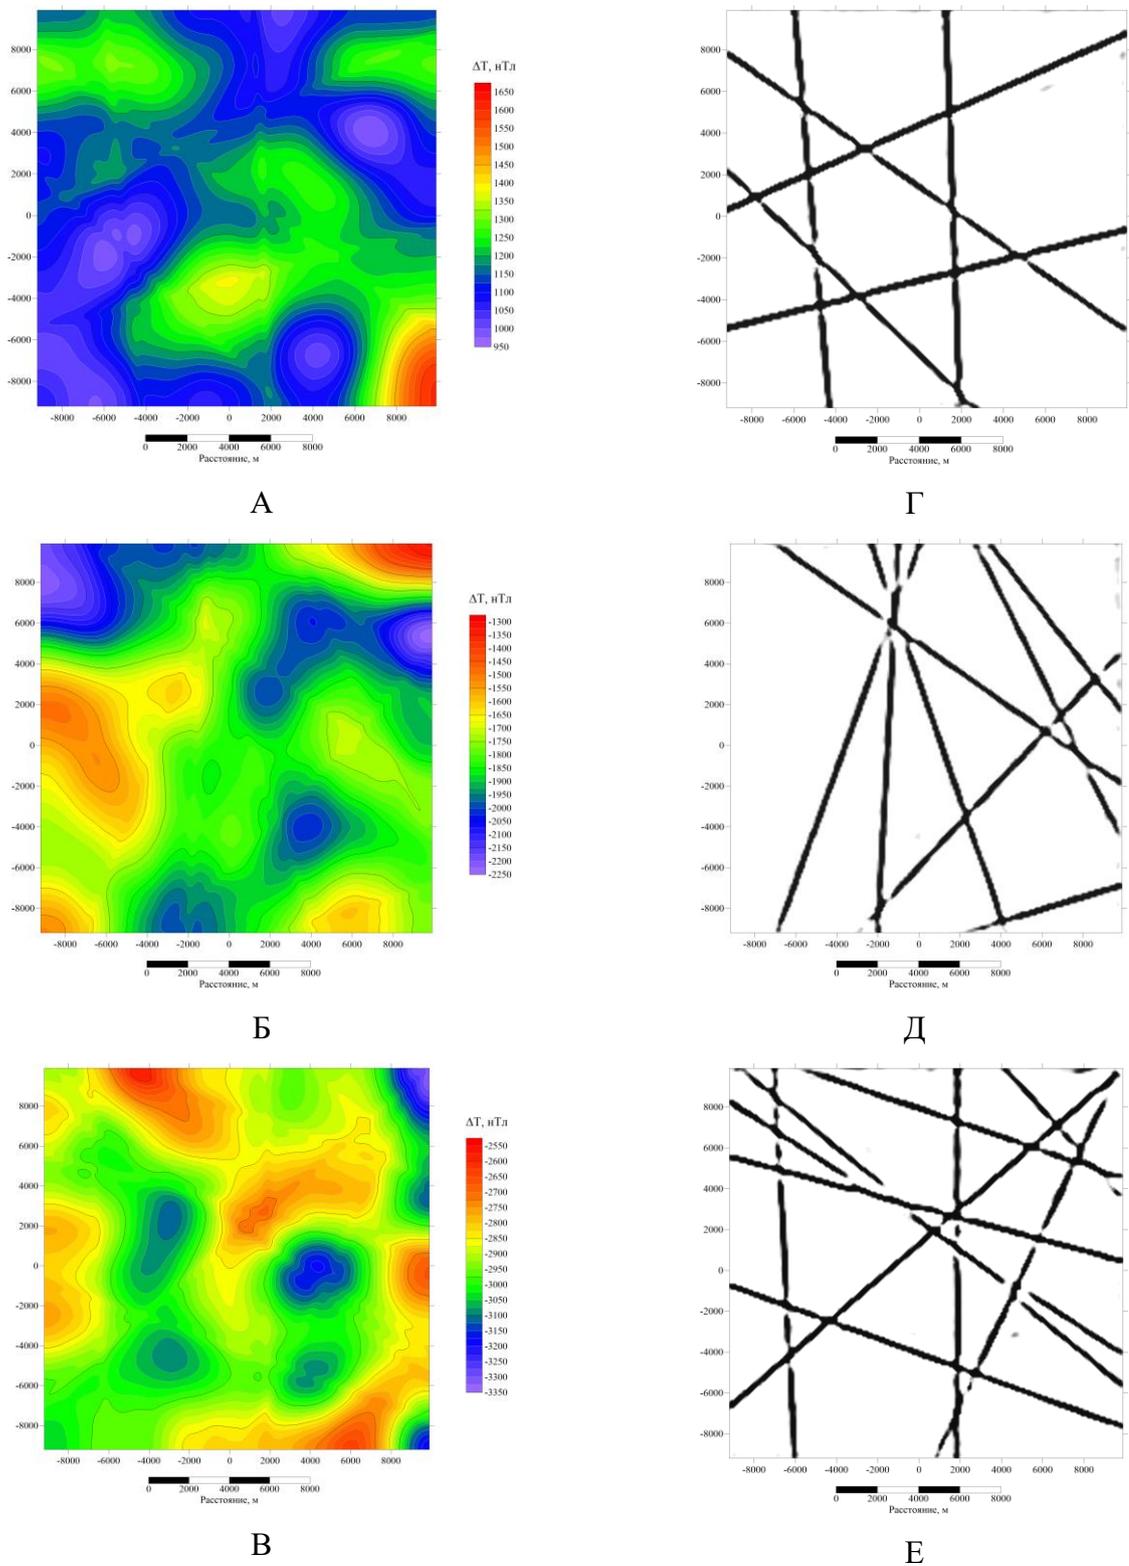


Рисунок 42 – Результат работы СНС на синтетических примерах: А-В – модельные примеры с линейными аномалиями; Г-Е – выделенные линейаменты с помощью СНС

4.3. Анализ устойчивости к вариациям ширины аномалий

Для оценки устойчивости модели к вариациям геометрии источников проведен эксперимент с постепенным увеличением ширины линейной аномалии за счет увеличения размера источника. На начальных этапах СНС корректно выделяет единый линейный элемент (Рисунок 43А, Б). Однако при ширине свыше 600 метров сеть начинает интерпретировать объект как две параллельные аномалии (Рисунок 43В-Ж). Это связано с тем, что в обучающей выборке преобладали узкие линейные объекты (шириной 200-400 м), и модель не обобщила паттерны для широких объектов. Результат подчеркивает важность учета разнообразия геометрических параметров в обучающих данных.

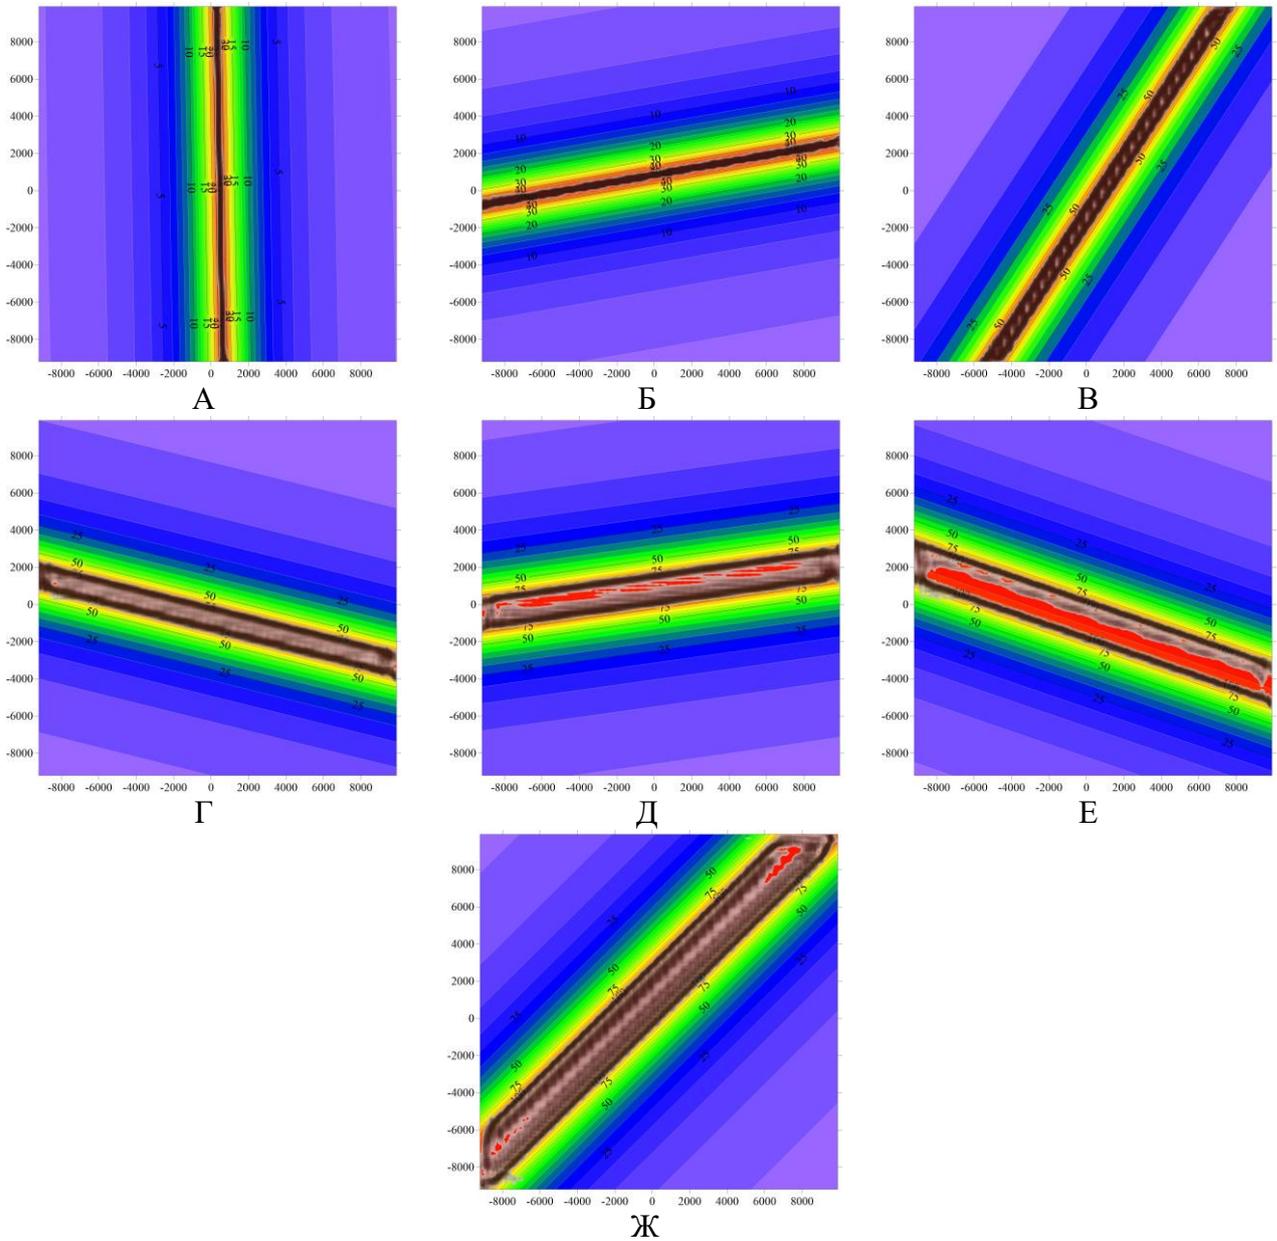


Рисунок 43 – Результат применения СНС к линейным объектам разной ширины: А – 200 м.; Б – 400 м; В – 600 м; Г – 800 м; Д – 1000 м; Е – 1200 м; Ж – 1400 м.

4.4. Аprobация обученной СНС на примере поля участка Баренцева моря

В качестве примера для отработки метода полученной СНС рассмотрено аномальное магнитное поле участка Баренцева моря. В регионе широко распространена сеть даек различного простирания, проявленных в магнитном поле в виде линейных аномалий [Лыгин и др., 2023]. В качестве примера рассмотрен небольшой участок (50×50 км) высокоточной детальной гидромагнитной съемки, в периметре которого в аномальном магнитном поле отчетливо проявляются крупные дайки (Рисунок 44). Предварительно, для использования обученной СНС, размерность модели аномального магнитного поля разрежалась до размера 192×192 ячейки. Стоит отметить, что рассматриваемый метод применим к картам любого размера. Чтобы применить СНС для данных другого размера необходимо выполнить две процедуры: 1) увеличение размера матрицы данных до размеров кратных 192 путем добавления ячеек с нулевыми значениями и 2) разделение всей области данных на блоки размером 192×192 ячейки.

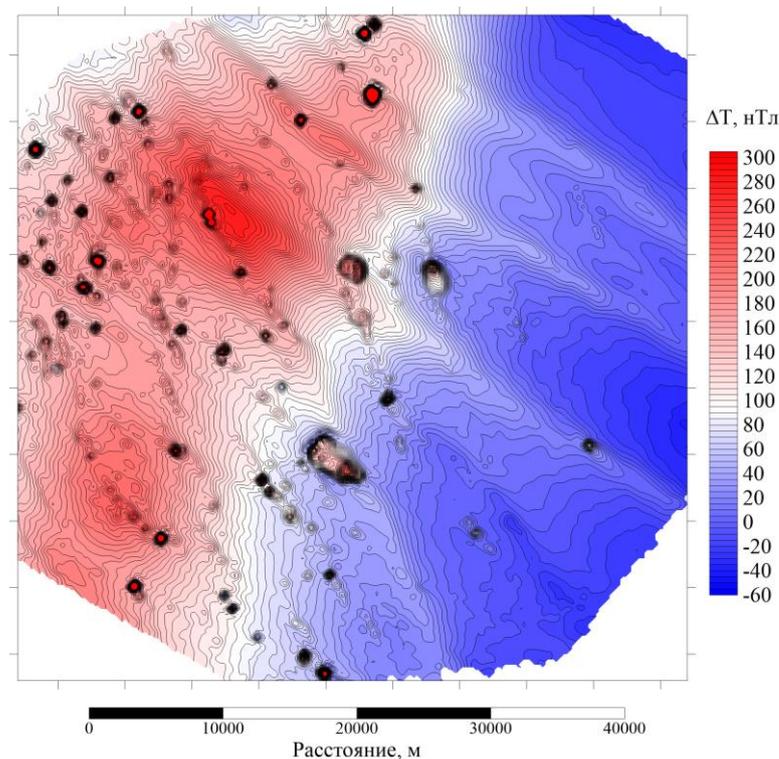


Рисунок 44 – Аномальное магнитное поле участка детальных гидромагнитных работ Баренцева моря

Сверточная нейронная сеть, обученная на синтетических моделях, применена к аномальному магнитному полю с целью выделения осей линейных аномалий, связанных с эффектом даек (Рисунок 44). На рисунке 45 представлено сравнение результатов СНС (черный цвет) и результатов комплексной интерпретации, описанной в работе [Соколова и др., 2015]

(желтый цвет). Стоит отметить, что несмотря на то, что в примерах из обучающей выборки максимальное количество линеаментов – 10, полученная СНС способна выделять неограниченное количество линейных элементов. Связано это в первую очередь с тем, что сеть не учитывает семантику "объектов", а лишь активирует соответствующие ячейки матрицы поля, похожие на обученные паттерны.

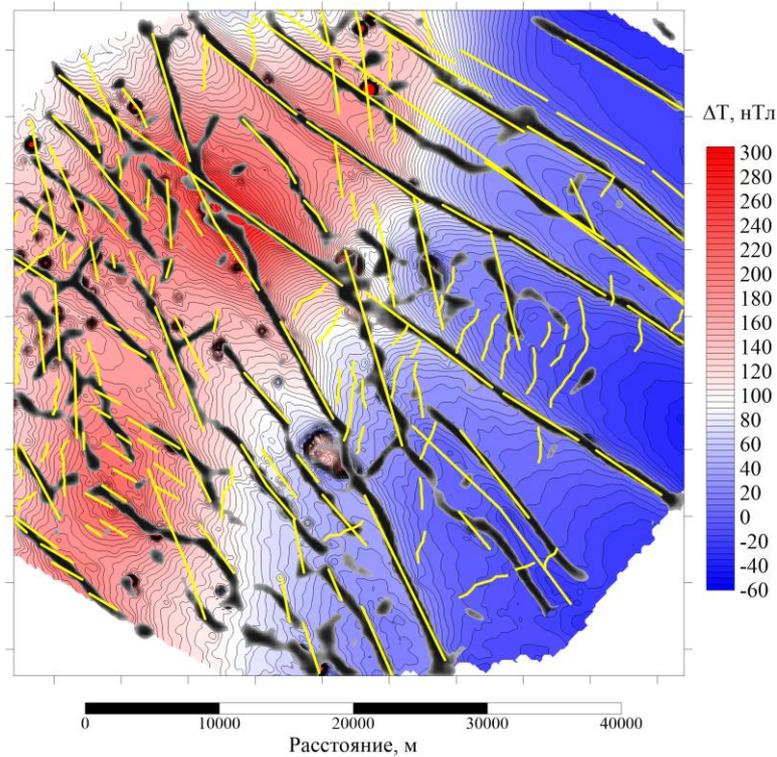


Рисунок 45 – Оси линейных аномалий магнитного поля, приуроченных к дайковому комплексу, полученные по результатам использования СНС (черный цвет) и по результатам комплексной интерпретации [Соколова и др., 2015] (желтый цвет)

Результат выделенных аномалий с помощью СНС визуально схож с результатом комплексной интерпретации. Однако при этом в результатах работы сети есть области, не выделенные экспертом. Также встречаются области, которые не связаны в единый массив, хотя и составляют цепочку. Для подтверждения выделенных линеаментов рассмотрена высокочастотная составляющая аномального магнитного поля (Фильтр высоких частот (ФВЧ) – 5 км) (Рисунок 46). Видно, что линеаменты, невыделенные с помощью комплексной интерпретации, но выделенные с помощью СНС, относятся к положительным линейным высокочастотным магнитным аномалиям. Дополнительно выделенные линеаменты требуют подтверждения с помощью других геофизических методов, например, сейсморазведки или данных бурения [Соколова и др., 2015].

Для повышения точности выделения осей линейных аномалий к результатам работы сверточной нейронной сети применен алгоритм скелетизации – преобразования бинарных масок в однопиксельные линии, сохраняющие топологию исходных объектов (Рисунок 47). Метод включает следующие этапы:

1. Скелетизация (алгоритм Чжана-Суэна [Zhang, Suen, 1984]) – исходная бинарная маска (где 1 – область аномалии, 0 – фон) итеративно истончается до тех пор, пока не останутся только центральные оси линеаментов.

2. Фильтрация по длине линии. Используется чтобы удалить шумовые артефакты (например, короткие разрывы или ложные линии), применен фильтр, исключающий все объекты короче 10 пикселей.

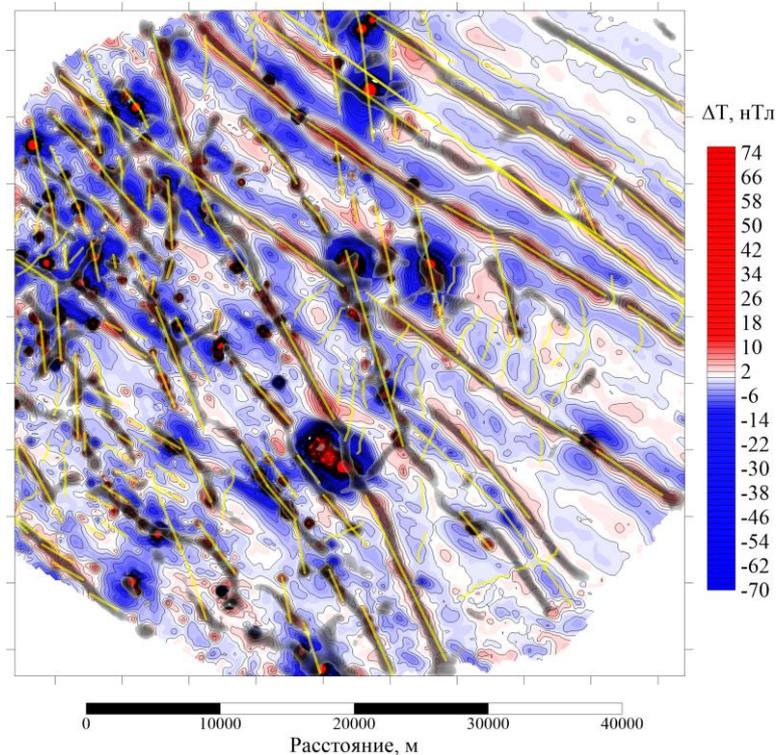


Рисунок 46 – Высоочастотная составляющая аномального магнитного поля (ФВЧ – 5 км) с нанесенными осями линейных аномалий магнитного поля, приуроченных к дайковому комплексу, полученные по результатам использованием СНС (черный цвет) и по результатам комплексной интерпретации [Соколова и др., 2015] (желтый цвет)

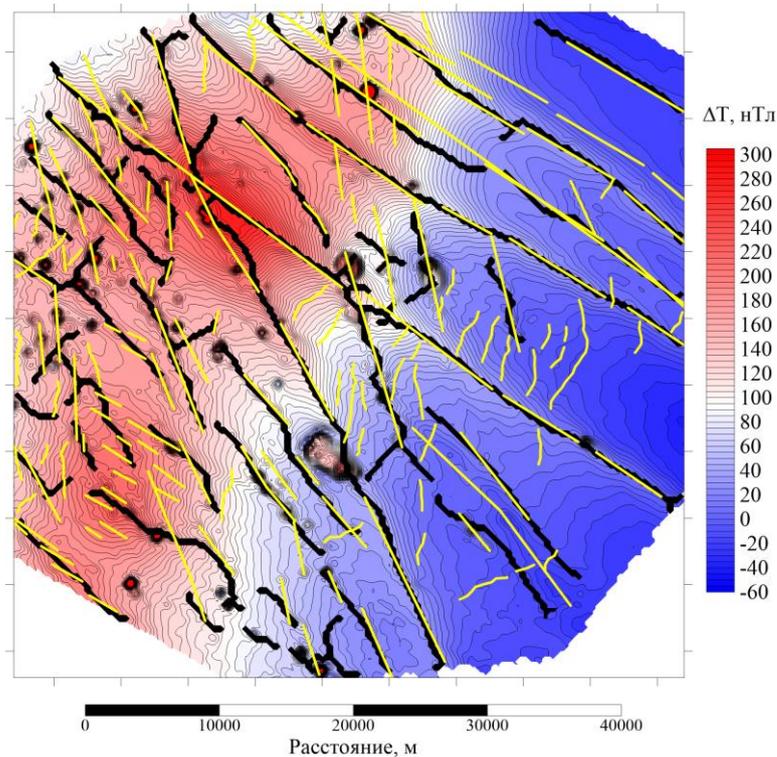


Рисунок 47 – Результат применения скелетизации

4.4.1 Сравнение с алгоритмом автоматического трассирования осей аномалий в КОСКАД 3D

Для оценки эффективности предложенного метода на основе сверточных нейронных сетей проведено сравнение с алгоритмом автоматического трассирования осей линейных аномалий, реализованным в программном комплексе КОСКАД 3D, использующим оригинальную модификацию одномерной адаптивной фильтрации [Петров, Трусов, 2000].

На тех же данных участка Баренцева моря (Рисунок 44) алгоритм КОСКАД 3D (Рисунок 48) показал следующие результаты: выделено несколько наиболее контрастных линейных магнитных аномалий (оси аномалий 1-го порядка), тогда как слабопроявленные объекты остались невыделенными (оси аномалий 2-го порядка). Кроме того, в выходных данных присутствует значительное количество ложных точечных аномалий, а сами линии представляют собой разрозненные точки, не объединённые в целостные линейные структуры.

В отличие от этого, предложенная СНС продемонстрировала более целостное выделение осей даже в условиях сложного фона, а также устойчивость к шуму благодаря обучению на синтетических моделях с помехами.

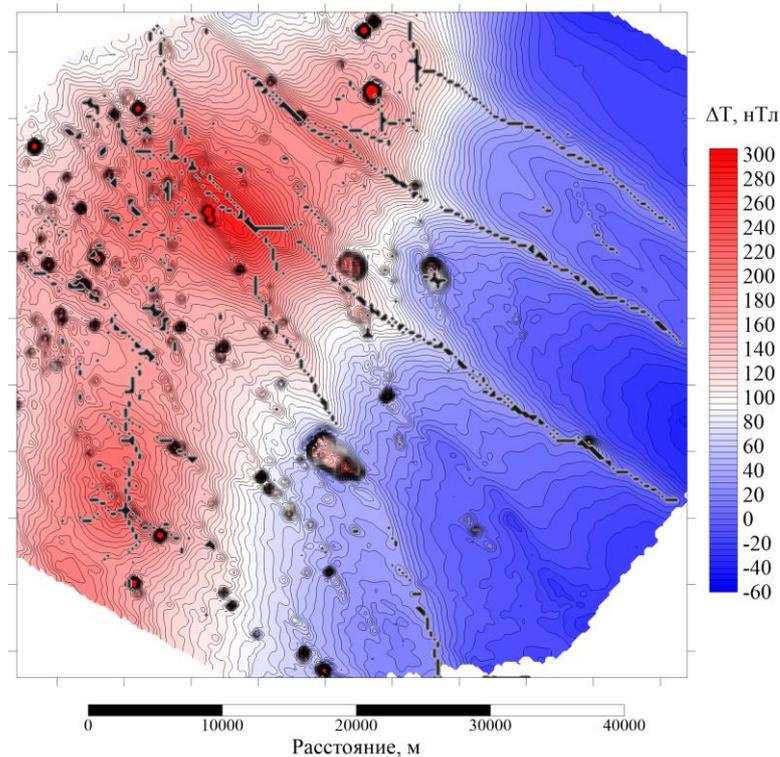


Рисунок 48 – Результат автоматического трассирования осей линейных аномалий, реализованным в программном комплексе КОСКАД 3D

4.5. Комплексный анализ изометричных и линейных аномалий на данных Баренцева моря

Для комплексного анализа магнитного поля участка Баренцева моря разработана методика выделения как линейных, так и изометричных аномалий. Источниками локальных магнитных аномалий являются приповерхностные глыбы интрузивного состава. Размеры аномалий – 600-800 метров, реже до 1 км в диаметре [Соколова и др., 2015]. В дополнение к уже описанной сети для линеаментов обучена отдельная нейронная сеть U-Net с архитектурой VGG-16, специализированная на обнаружении изометричных объектов.

Ключевым отличием методики создания синтетических данных для Земли от примененной в Главе 3 для Луны является модель источника. Если для лунных масконов использовалась третья вертикальная производная потенциала точечного источника с последующей обработкой, что обусловлено формой аномалий масконов Луны, то для земных условий в качестве модели изометричной аномалии использовался магнитный эффект положительного магнитного заряда. Данный подход более точно соответствует наблюдаемым эффектам приповерхностных геологических неоднородностей небольшой размерности в аномальном магнитном поле.

Эта сеть обучалась на 500 синтетических моделях, созданных с учетом описанного подхода. Методика включала в себя автоматическую бинаризацию с использованием метода

Оцу, которая позволила разделить аномальные области и фон, а последующее удаление шумовых объектов малого размера существенно улучшило качество выделения значимых структур (Рисунок 49).

В ходе автоматизированного анализа подтверждено 95%, выделенных в результате комплексной интерпретации изометричных объектов, также выявлено более сотни новых аномалий (Рисунок 50). Особенно важно отметить, что метод успешно справился с обработкой обширного массива данных за несколько секунд, что на несколько порядков быстрее, чем традиционные методы ручной экспертной интерпретации. Для подтверждения выделенных изометричных объектов рассмотрена высокочастотная составляющая аномального магнитного поля (Фильтр высоких частот (ФВЧ) с периодом среза 5 км) (Рисунок 51). Видно, что объекты, невыделенные с помощью комплексной интерпретации, но выделенные с помощью СНС, относятся к положительным изометричным магнитным аномалиям.

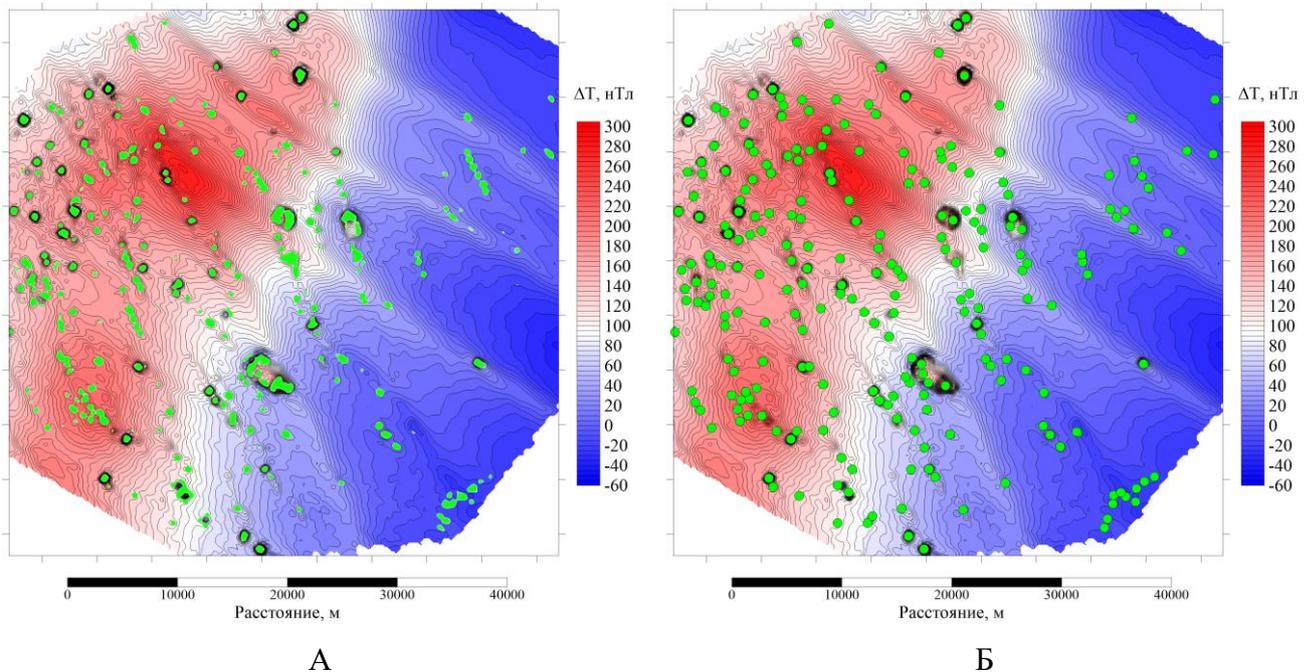


Рисунок 49 – Контуры изометричных аномалий магнитного поля, приуроченных к приповерхностным источникам, полученные по результатам использования СНС(А) и результат сепарации аномалий с помощью метода Оцу (Б)

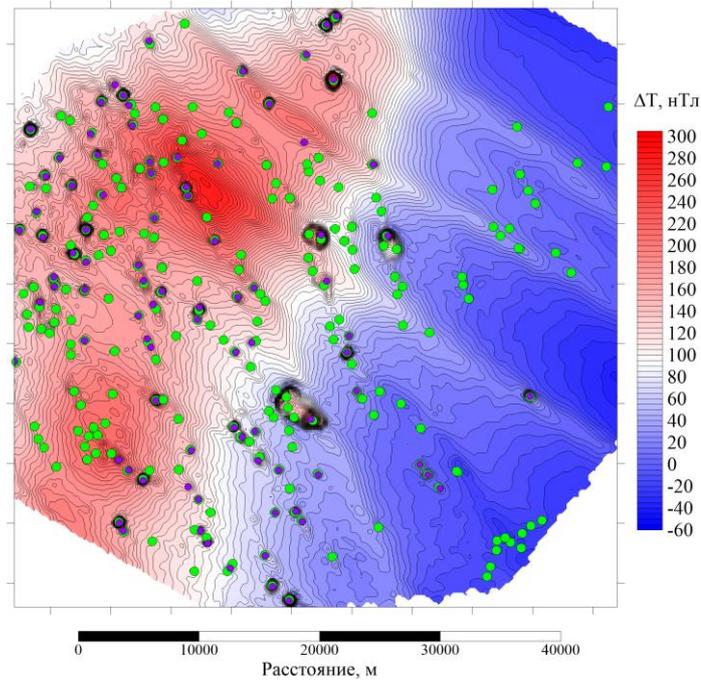


Рисунок 50 – Изометричные аномалии магнитного поля, приуроченных к приповерхностным магнитным источникам, полученные по результатам использованием СНС (зеленый цвет) и по результатам комплексной интерпретации [Соколова и др., 2015] (фиолетовый цвет)

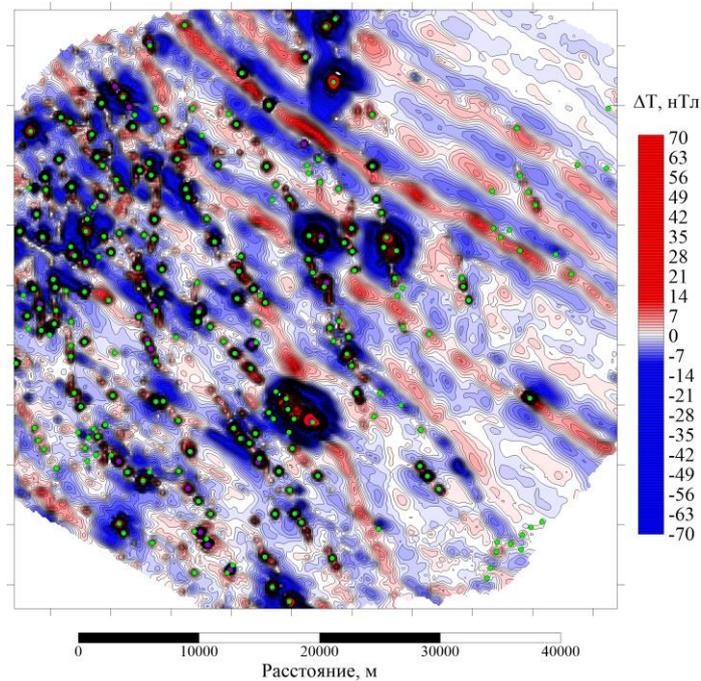


Рисунок 51 – Высокочастотная составляющая аномального магнитного поля (ФВЧ – 5 км) с нанесенными изометричными аномалиями магнитного поля, приуроченных к приповерхностным магнитным источникам, полученные по результатам использованием СНС (зеленым цвет) и по результатам комплексной интерпретации [Соколова и др., 2015] (фиолетовым цвет)

Дополнительно, для выделения крупных изометричных аномалий, матрица аномального магнитного поля была разрежена в 5 раз (Рисунок 52). Сравнение с экспертной интерпретацией показало, что метод визуально коррелирует с результатом ручной интерпретации, при этом обнаруживая несколько новых перспективных аномалий. Применение двух независимых сетей к данным Баренцева моря позволило получить комплексную картину геологических структур (Рисунок 53).

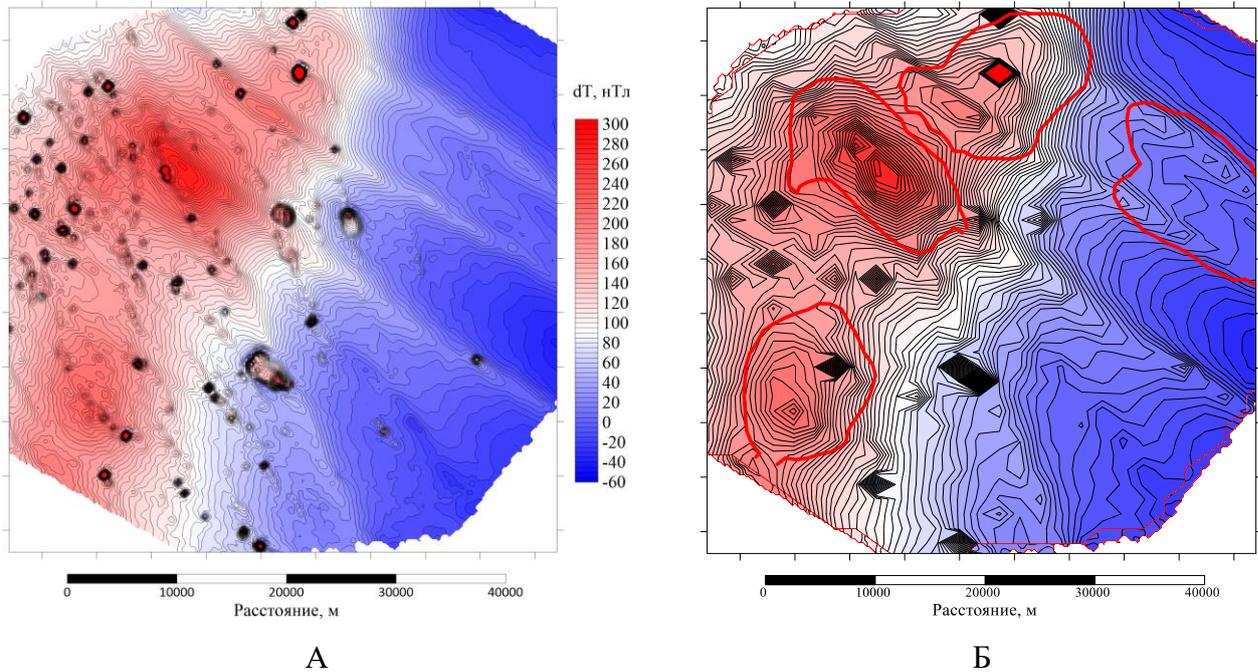


Рисунок 52 – Выделение крупных магнитных аномалий с помощью СНС посредством сжатия исходной матрицы (А) в 5 раз (Б)

Полученные результаты демонстрируют, что комбинированное применение специализированных сверточных сетей позволяет значительно повысить полноту и скорость интерпретации магнитных данных. Метод не только подтверждает известные выделенные структуры, но и выявляет новые перспективные аномалии, требующие дополнительного изучения. При этом сохраняется необходимость интеграции с другими геофизическими методами и геологическими данными для окончательной верификации результатов интерпретатором.

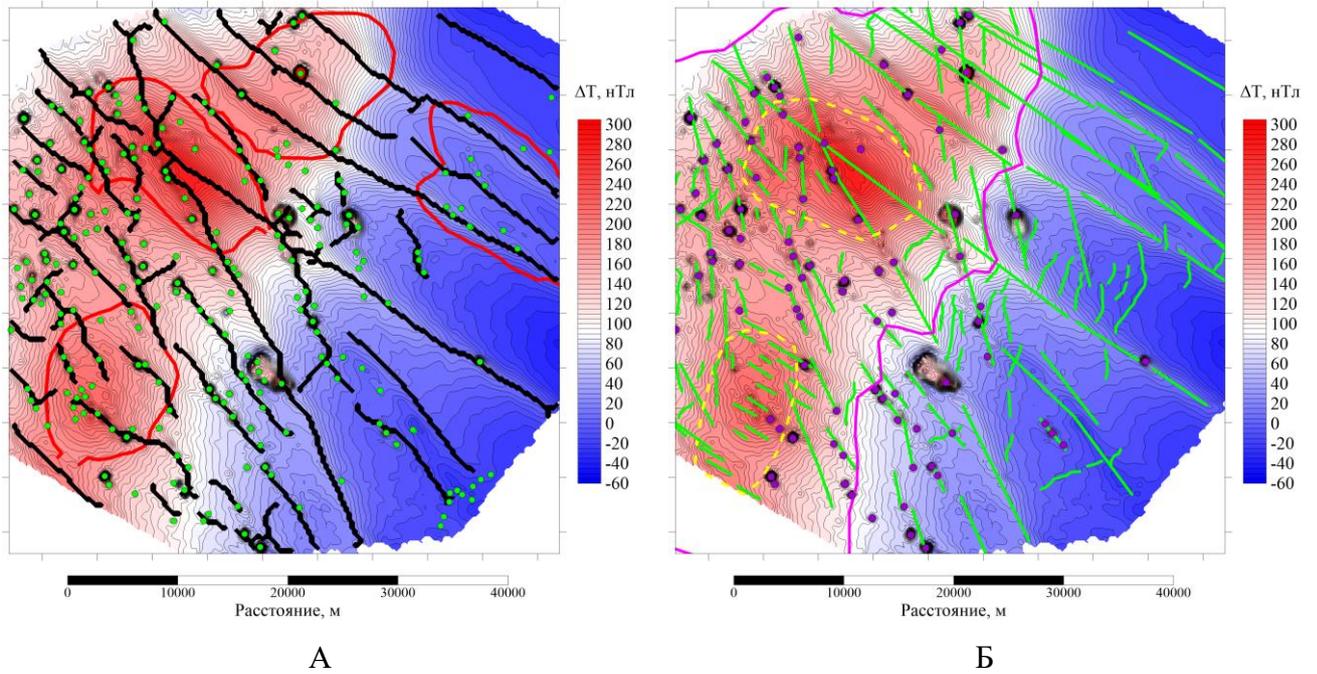


Рисунок 53 – Аномальное магнитное поле Баренцевоморского региона с нанесенными элементами интерпретации. А – результат работы СНС; Б – результат комплексной экспертной интерпретации [Соколова и др., 2015]

4.6. Выводы по Главе 4

Разработан и апробирован метод автоматизированного выделения линейных аномалий магнитного поля на основе сверточных нейронных сетей. В качестве архитектуры была выбрана U-Net с энкодером на основе предобученной сети VGG-16. Модель была дообучена на синтетически рассчитанных данных.

Применение предложенного подхода к аномалиям магнитного поля участка Баренцева моря выявило его преимущества по сравнению с традиционными подходами. Подтверждено подавляющее большинство линеаментов и изометричных аномалий, известных по результатам ручной интерпретации, а также выявлены новые перспективные объекты, требующие дальнейшего изучения. Особенно важно отметить, что автоматизированный анализ выполняется на несколько порядков быстрее экспертной интерпретации, что делает предлагаемый подход удобным инструментом в интерпретации магнитных и гравитационных полей.

Экспериментальные исследования выявили и некоторые ограничения метода. Наиболее существенные из них связаны с зависимостью качества выделения от геометрических параметров объектов (например, разделение широких линейных аномалий на параллельные структуры) и необходимостью последующей экспертной проверки результатов, особенно в сложных геологических условиях. Эти ограничения указывают направления для дальнейшего

совершенствования метода, включая расширение разнообразия обучающей выборки и разработку дополнительных критериев классификации объектов.

Также рассмотрено комплексное применения подхода к выделению изометричных и линейных аномалий для составления интерпретационных схем аномалий с дальнейшей возможностью увязки их с объектами тектоники.

Глава 5. Восстановления структурных границ по геофизическим данным на основе нейронных сетей³

На этапе мелко и среднемасштабных геолого-геофизических исследований обычно помимо сейсморазведки активно применяются методы гравиразведки и магниторазведки, которые в отличие от профильных сейсмических наблюдений особенно с учетом современных спутниковых и авиационных технологий обеспечивают качественную площадную плотностную и магнитную характеристику района исследования. К основным задачам, стоящим перед гравиразведкой и магниторазведкой на данных этапах, относится задача построения площадных моделей границ разреза, разделяющих контрастные по плотности или намагниченности слои. Среди большого числа алгоритмических решений наиболее эффективными являются методы, основанные на комплексном подходе, в котором в качестве эталона используются сейсмические данные о морфологии структурных горизонтов. Важным является учет максимального объема имеющейся априорной информации, к которой можно отнести положение нецелевых границ разреза, например, граница Мохоровичича, подошва осадочного чехла, дневной рельеф, рельеф морского дна и др.

Восстановление морфологии структурной поверхности по геофизическим данным возможно рассмотреть как задачу поиска зависимости между входной информацией (потенциальными полями, геофизическими данными, имеющейся априорной информацией) и искомой поверхностью. Для оценки зависимости предлагается использовать эталонные участки, то есть те, на которых представлены как входные, так и выходные данные. В настоящее время одним из трендовых направлений в решении такого рода задач является использование алгоритмов, основанных на построении различных регрессионных зависимостей. При этом активное развитие имеют методы на основе нейронных сетей. Регрессия может быть описана различными математическими законами, как линейными, так и нелинейными, также она может быть множественной [Никитин, Петров, 2008].

Самый простой случай – линейная регрессия, которая представляется в виде уравнения прямой, аппроксимирующей взаимосвязь между входными переменными x и выходными переменными y :

³ При подготовке данного раздела диссертации использована следующая публикация, выполненная автором в соавторстве, в которой, согласно Положению о присуждении ученых степеней в МГУ, отражены основные результаты, положения и выводы исследования:

Шклярук А.Д., Кузнецов К.М. Применение машинного обучения для построения структурных границ разреза по потенциальным полям // Гелиогеофизические исследования. 2023. № 38. С. 18-29. EDN: QKYCJY (0.75 п.л., авторский вклад 50%). Импакт-фактор 0.370 (РИНЦ).

$$y = \beta_0 + \beta_1 x, \quad (19)$$

где β_0 – свободный член, β_1 – коэффициент регрессии [Никитин, Петров, 2008]. В общем виде коэффициенты могут рассматриваться, как векторы размерности N – количество независимых атрибутов входной информации, например, трансформант потенциальных полей.

Нелинейную регрессию можно описать с помощью Гауссовского процесса, который является также одним из возможных способов задания зависимости одного параметра от другого. Модель гауссовской регрессии можно описать следующим выражением [Бурнаев и др., 2013]:

$$y(x) = f(x) + \varepsilon(x), \quad (20)$$

где $f(x)$ – реализация некоторого гауссовского процесса, $\varepsilon(x) \sim N(0, \sigma^2)$ – белый шум, где σ^2 – ковариационный шум гауссовского процесса.

Стоит отметить, что алгоритмы регрессии не всегда позволяют описать сложные функциональные связи между потенциальными полями и границами разреза. В качестве одного из подходов может быть предложено решение на основе нейронных сетей. Они могут быть различной конфигурации (сети прямого распространения, сети радиально-базисных функций, сети обратного распространения, сверточные сети и др.) и могут иметь различное число слоев и нейронов.

В данном разделе работы рассмотрены многослойные нейронные сети прямого распространения. Обучение нейронных сетей происходит с использованием метода обратного распространения ошибки, то есть после прохода данных нейронная сеть сравнивает их с желаемым выходом и корректирует веса связей (синапсов) в направлении от выходного слоя к входному.

В качестве примера на рисунке 54 представлена схема двухслойной нейронной сети. Первый слой – скрытый, состоящий из 30 нейронов, второй – выходной, состоит из 3 нейронов. Рассмотрим принцип работы нейронной сети:

1. На вход поступает 12 значений, они перемножаются с синаптическими весами связи (w) с 30 нейронами, суммируются и к сумме прибавляется вектор смещения – b .
2. После этого сумма проходит через функцию активации.
3. Далее выход первого слоя попадает в выходной слой, где происходят те же преобразования, что и в первом слое. Количество нейронов в выходном слое равно количеству выходных параметров; в данном случае их три.

Стоит отметить, что для поиска более сложных зависимостей возможно использование рекуррентных нейронных сетей. Их особенностью является то, что выходной сигнал после

прохода одного слоя, возвращается в него как второй набор входных данных. Зачастую такой подход позволяет подобрать веса нейронной сети, которые обеспечивают минимальную невязку. Однако, использование рекуррентных нейронных сетей увеличивает время вычисления.

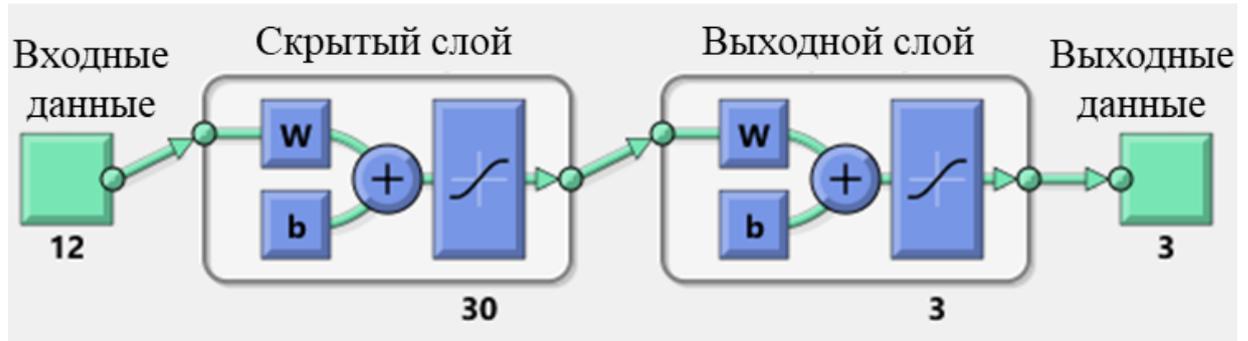


Рисунок 54 – Схема двухслойной нейронной сети с 30 нейронами в первом слое

5.1. Сравнение методов машинного обучения для оценки возможности восстановления поверхности горизонтов на модельном примере

В качестве тестовой модели для демонстрации принципиальной возможности восстановления поверхности горизонтов по комплексу сейсморазведочных данных и данных гравиразведки и магниторазведки рассмотрен участок с известным положением подошвы осадочного чехла на территории Баренцева моря. Размер участка $1\ 578 \times 870$ км (790×436 точек), расстояние между точками – 2 км. Для верификации и сравнения методов машинного обучения (нейронная сеть и гауссова регрессия) рассчитаны гравитационный (Рисунок 55Б) и магнитный (Рисунок 55А) эффекты слоя в предположении, что выше него плотность и намагниченность равны $0\ \text{г/см}^3$ и $0\ \text{А/м}$ соответственно. Ниже границы плотность – $1\ \text{г/см}^3$, а намагниченность считается индуцированной при магнитной восприимчивости 0.001 ед. СГС и параметрах нормального поля: наклонение – 90° , склонение – 0° , амплитуда – 60 000 нТл. Для оценки точности работы методов машинного обучения из рельефа подошвы осадочного чехла «вырезан» участок (Рисунок 55В). На вход методам для построения регрессионной зависимости и обучения нейронной сети подавались гравитационное и магнитное поля. Задача методов заключалась в том, чтобы восстановить вырезанный участок рельефа подошвы осадочного чехла по потенциальным полям. Для обучения использовалось 294 440 точек, общий объем исходных данных составил 344 440 точек.

Для примера представлено сравнение результатов восстановления рельефа подошвы осадочного чехла с применением метода на основе двухслойной нейронной сети с 30 нейронами в каждом слое (Рисунок 55Д) и алгоритма на основе гауссовой регрессии (Рисунок 55Г).

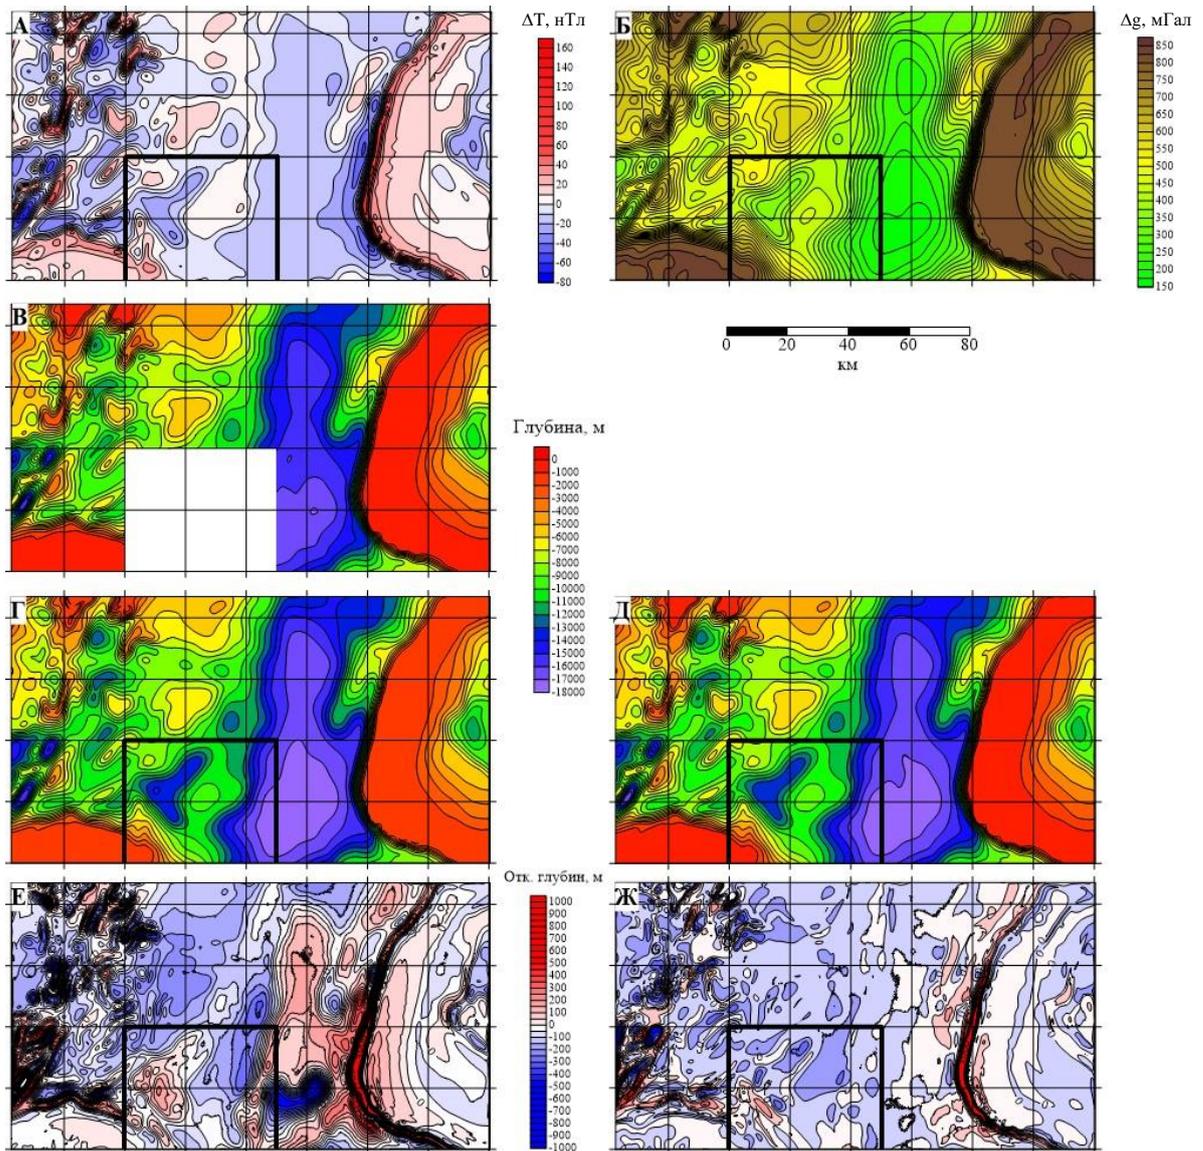


Рисунок 55 – Результаты восстановления подошвы осадочного чехла.

Исходные данные: А – магнитное поле; Б – гравитационное поле, В – глубина до подошвы осадочного чехла с «вырезанным» фрагментом. Результаты: восстановленная глубина до подошвы осадочного чехла алгоритмом на основе гауссовой регрессии (Г), методом на основе нейронных сетей (Д); расхождения с модельной глубиной подошвы для алгоритма на основе гауссовой регрессии (Е), метода на основе нейронных сетей (Ж)

Оценки среднеквадратического отклонения (СКО) между модельной границей и рассчитанной с помощью нейронной сети (Рисунок 55Ж) и гауссовой регрессии (Рисунок 55Е) на восстановленном участке составили ± 79 и ± 112 м соответственно при перепаде глубин подошвы осадочного чехла от первых сотен метров до 18 км. Расхождения наибольшей амплитуды приурочены к областям с высоким градиентом изменения рельефа подошвы осадочного чехла.

Проведенный модельный эксперимент демонстрирует принципиальную возможность применения методов машинного обучения, в частности нейронных сетей и гауссовой регрессии, для решения задачи восстановления структурных границ по данным потенциальных полей. Результаты подтверждают, что рассматриваемые методы способны эффективно выявлять сложные, неочевидные зависимости между пространственным распределением геофизических полей и морфологией глубинных границ разреза.

5.2. Сравнение различных архитектур нейронных сетей для восстановления поверхности горизонтов в межпрофильном пространстве на модельном примере

Для оценки возможности построения контрастной по плотности границы на основе метода нейронных сетей рассмотрен модельный пример. Размер участка 300×300 км (1 002 001 точка), расстояние между точками расчета поля – 300 метров (Рисунок 56А)

Для верификации и сравнения алгоритмов в программе GravMagInv3D [Чепиго, 2020] рассчитан гравитационный эффект в предположении, что нижележащий слой имеет постоянную избыточную по отношению к вышележащему плотность 0.5 г/см^3 (Рисунок 56Б).

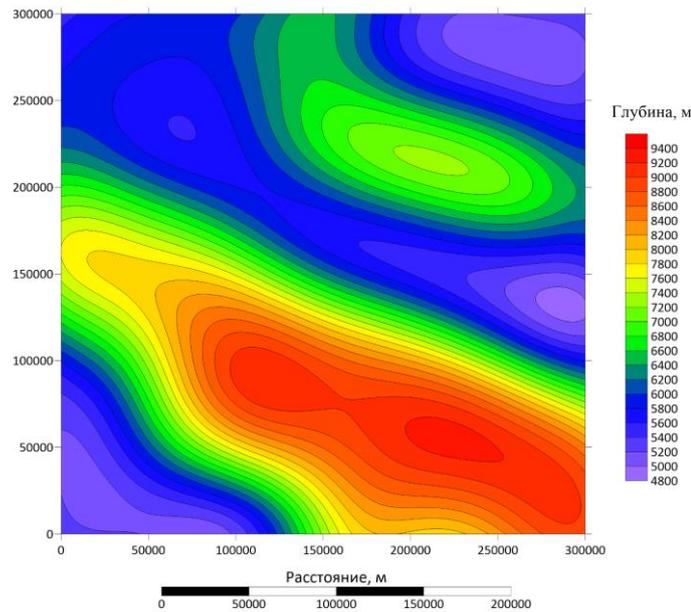
В качестве первого этапа для выбора наилучших параметров нейронной сети для обучения использован полный массив данных. Такой подход позволяет оценить с какой точностью можно восстановить связь между горизонтом и рассчитанным от него гравитационным эффектом. На вход нейронной сети подавались значения гравитационного эффекта в каждой ячейки поля, а на выход – соответствующая данной ячейке глубина залегания горизонта.

Для выбора эффективной архитектуры нейронной сети варьировались следующие параметры:

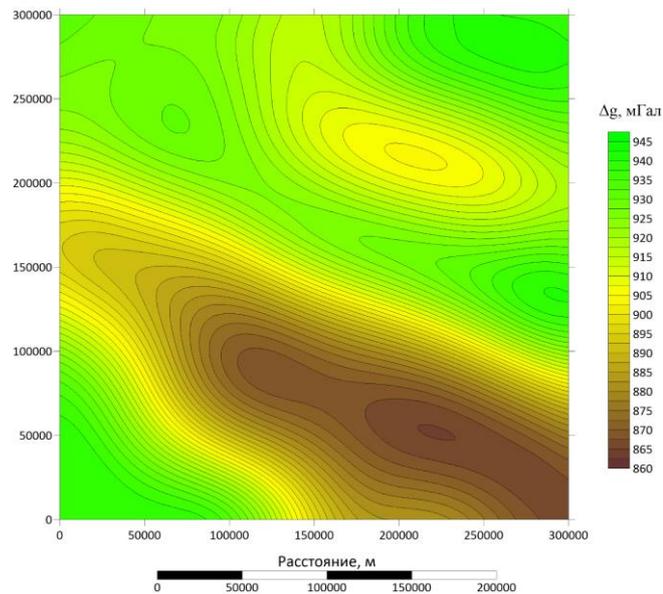
1. Количество скрытых слоев (от 1 до 10);
2. количество нейронов в слоях (от 5 до 10000);
3. функции активации для каждого слоя (линейная, сигмоида, гиперболический тангенс, ReLu);
4. скорость обучения (от 0.00001 до 1).

Выбор функции активации во многом зависит от поставленной задачи. Для задачи восстановления горизонта, как задачи регрессии, в скрытых слоях нейронной сети целесообразно применение функций активации семейства ReLU (Leaky ReLU, PReLU, RReLU), которые благодаря своей нелинейности и отсутствию насыщения на большей части области определения позволяют сети эффективно аппроксимировать сложные зависимости, а в выходном слое – линейной функции активации, что обеспечивает получение непрерывного спектра значений глубины [Goodfellow et al., 2016]. Одной из проблем стандартного ReLU является затухающий, а именно нулевой, градиент при отрицательных значениях. При использовании обычного ReLU

часть нейронов приобретут нулевые веса, а отследить это не просто. Чтобы решить эту проблему иногда используется подход ReLU с «утечкой» (Leaky) – график функции активации на отрицательных значениях образует не горизонтальную прямую, а наклонную, с маленьким угловым коэффициентом (порядка 0.01). В дальнейшем эти функции будут использоваться во всех слоях нейронной сети, кроме последнего выходного слоя, в котором используется линейная функция активации для получения на выходе всего возможного диапазона глубины до границы.



А



Б

Рисунок 56 – Структурный горизонт (А) и его гравитационный эффект (Б)

Для решения конкретно поставленной задачи необходимо выбирать конкретную архитектуру нейронной сети. При этом в литературе не встречается четких подходов или правил

по ее выбору. Поэтому для каждого эксперимента архитектура нейронной сети выбирается эмпирически. Для оценки качества восстановления горизонта построены 13 различных нейронных сетей с различным количеством слоев и нейронов. Для данного эксперимента в нейронных сетях последовательно увеличивалось сначала количество нейронов для однослойной сети, после для двухслойной. Увеличение количества нейронов в слоях не привело к уменьшению ошибки (Таблица 8), последовательное увеличение количества слоев также не привело к улучшению результатов. Однако, наилучшая точность получена с применением сети с последовательным увеличением числа нейронов к 5 слою. По проведенному эксперименту можно сделать вывод, что для поиска зависимости между гравитационным полем и горизонтом лучше использовать простую структуру сетей с небольшим числом нейронов. Для оценки качества работы всех протестированных архитектур нейронных сетей было рассчитано среднеквадратическое отклонение (СКО) (Таблица 8). По результатам этого анализа были отобраны три архитектуры нейронных сетей: однослойная со 100 нейронами в слое, двухслойная с 15 нейронами в обоих слоях и десятислойная с различным количеством нейронов в слоях, которые показали наилучшую точность восстановления горизонта порядка 100 метров (<2%). Для этих трех архитектур с наименьшим отклонением от модельной границы были построены расхождения между модельным и рассчитанным положением границы (Рисунок 57), наглядно демонстрирующие пространственное распределение ошибок.

Таблица 8 Оценка среднеквадратического отклонения для различных архитектур нейронных сетей

Тип нейронной сети	СКО, м
1 слой – 5 нейронов	217
1 слой – 10 нейронов	136
1 слой – 100 нейронов	105
1 слой – 1000 нейронов	128
2 слоя – 10 нейронов	138
2 слоя – 15 нейронов	107
2 слоя – 20 нейронов	116
2 слоя – 100 нейронов	117
3 слоя – 10 нейронов	139
5 слоев – 10 нейронов	205
5 слоев – 100 нейронов	125
10 слоев – 100 нейронов	124
10 слоев – 16-32-64-128-256-256-128-64-32-16 нейронов	104

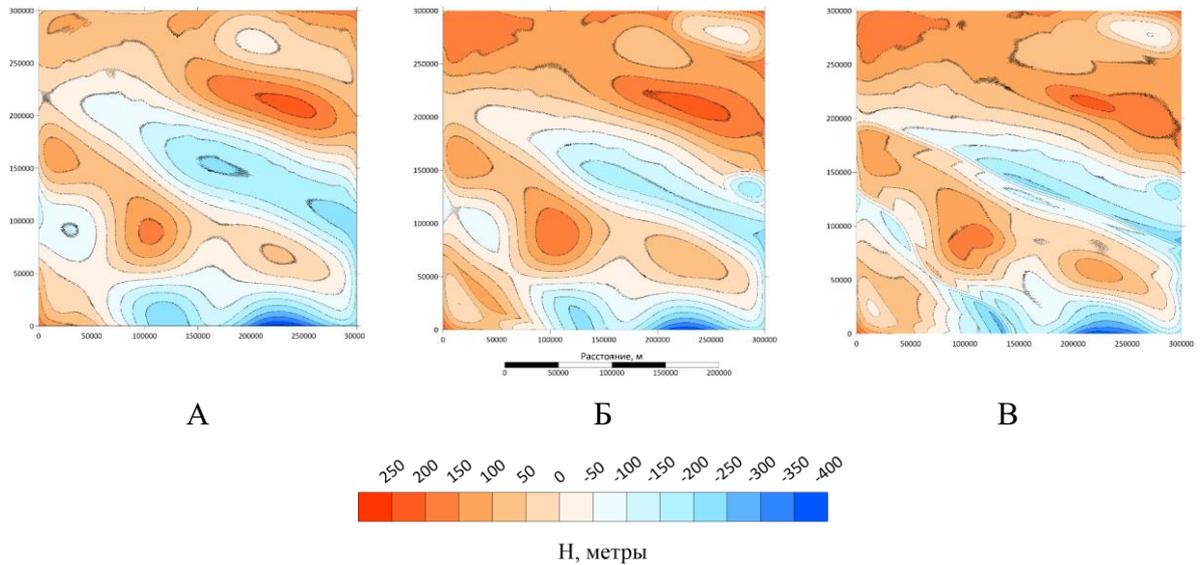


Рисунок 57 – Отклонения горизонта, полученного с использованием нейронных сетей и модельного: А – для однослойной нейронной сети со 100 нейронами; Б – для двухслойной нейронной сети с 15 нейронами в каждом слое; В – для десятислойной нейронной сети

Для оценки возможности применения нейронных сетей при решении задачи восстановления контрастных по свойствам поверхностей в межпрофильном пространстве составлено 6 различных разреженных моделей исходного горизонта с различным расстоянием между профилями (Рисунок 58). Было выбрано расстояние между профилями: 10 км, 20 км, 30 км, 40 км, 50 км, 100 км. Количество точек, использованных для обучения нейронной сети, и их доля от общего числа точек представлены в таблице 9.

Таблица 9 Количество точек и процентное соотношение от общего числа для различных сетей профилей

Расстояние между профилями, км	0.3	10	20	30	40	50	100
Количество точек для обучения	1002001	172964	89008	60122	44535	36684	18924
Процент от общего числа точек	100%	17.3%	8.9%	6%	4.4%	3.7%	1.9%

Обучение нейронных сетей, выбранных выше, проводилось с помощью полученных массивов данных для сетей профилей с различным расстоянием между ними. Результат применения трех выбранных нейронных сетей представлен в таблице 10.

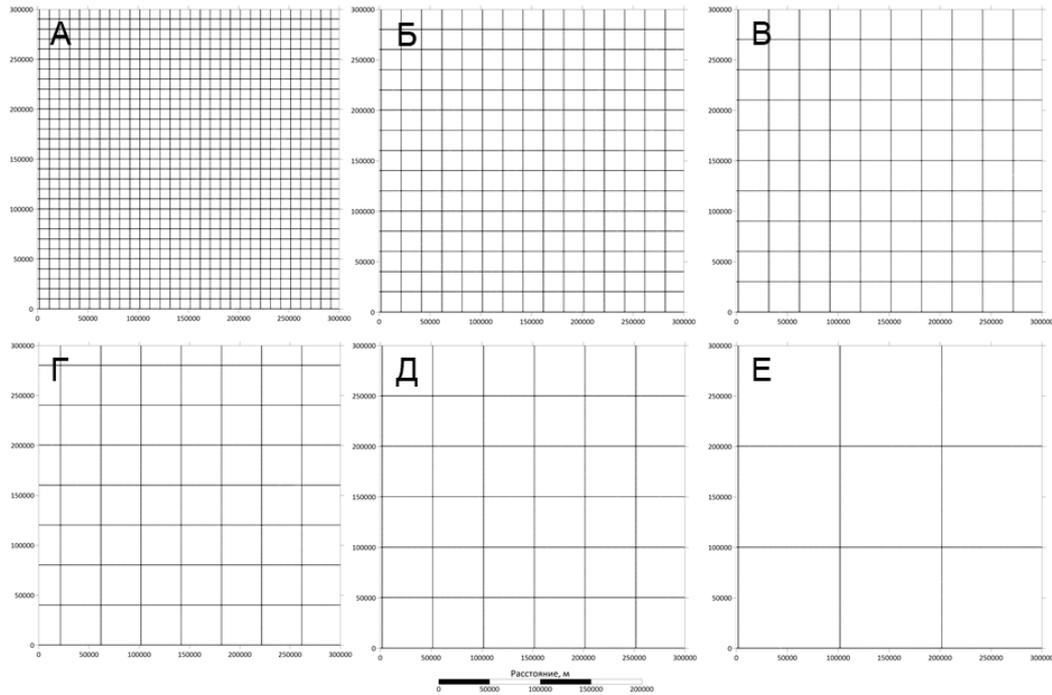


Рисунок 58 – Сети профилей для формирования массивов для обучения нейронных сетей с расстоянием между профилями:

А – 10 км; Б – 20 км; В – 30 км; Г – 40 км; Д – 50 км; Е – 100 км

Таблица 10 Результат работы нейронных сетей в задаче интерполяции данных на площади

Тип нейронной сети	Расстояние между профилями, км					
	10	20	30	40	50	100
	СКО, м					
1 слой – 100 нейронов	105	107	106	105	105	129
2 слоя – 15 нейронов	110	111	106	110	141	131
10 слоев – 16-32-64-128-256-256-128-64-32-16 нейронов	104	105	104	109	108	111

Таким образом, для рассмотренной задачи, имея данные о глубине горизонта по профилям, покрывающим лишь 5% площади, можно восстановить его на всю площадь, не потеряв при этом в точности. Для профильных данных через 50 и 100 км точность начинает существенно ухудшаться. Помимо этого, при обучении возникают ситуации, когда точность обучения не сходится и приходится менять параметры обучения. Для анализа полученных карт был проведен профиль (Рисунок 59) и оценено качество восстановления горизонта для сети профилей с шагом 100 км для трех нейронных сетей. По графику на рисунке 60 можно сделать вывод, что максимальные расхождения наблюдаются в экстремумах аномалий гравитационного поля. Наблюдаемые «полки» на краях профиля связаны с тем, что это области наиболее приподнятой части горизонта. В массиве обучающей выборки таких глубин представлено не

было, из-за чего рассмотренные модели нейронной сети не позволили предсказать данные значения.

Реконструкция структурного горизонта возможна и путем прямого подбора (решение обратной задачи). Рассматриваемый горизонт был восстановлен с помощью технологии автоматизированного подбора, реализованной в программе GravMagInv3D. Для более корректного решения задачи, в качестве априорной информации была задана истинная избыточная плотность. В качестве стартовой модели использовался горизонтальный слой с глубиной равной среднему значению глубины модельного горизонта. Результат подбора представлен на рисунке 61. СКО составило 50 метров, что в два раза лучше, чем результат работы нейронной сети. Однако стоит отметить, что для корректного решения обратной задачи важно иметь априорную модель. Оба рассмотренных подхода показали сопоставимые вычислительные затраты.

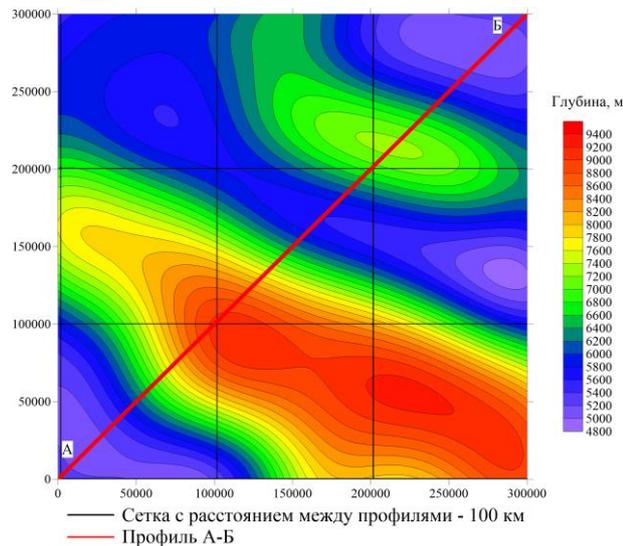


Рисунок 59 – Исходный структурный горизонт с положением сети профилей для обучения и контрольного профиля А-Б

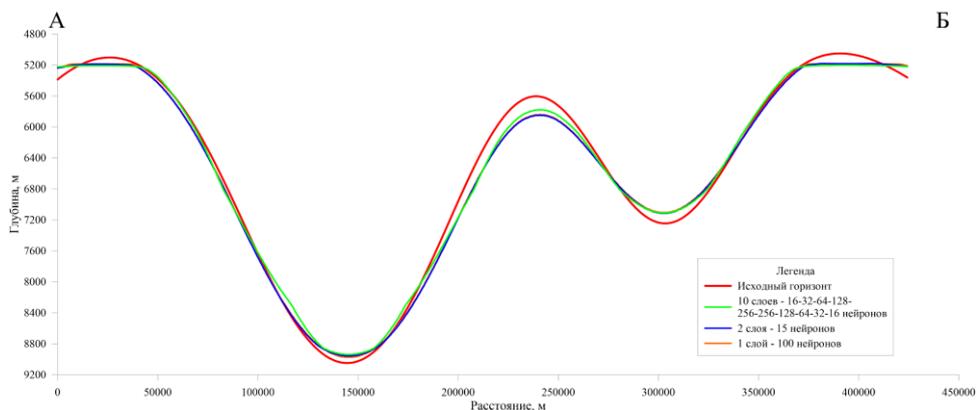


Рисунок 60 – Сравнение исходного и полученного с помощью нейронных сетей горизонтов по профилю А-Б

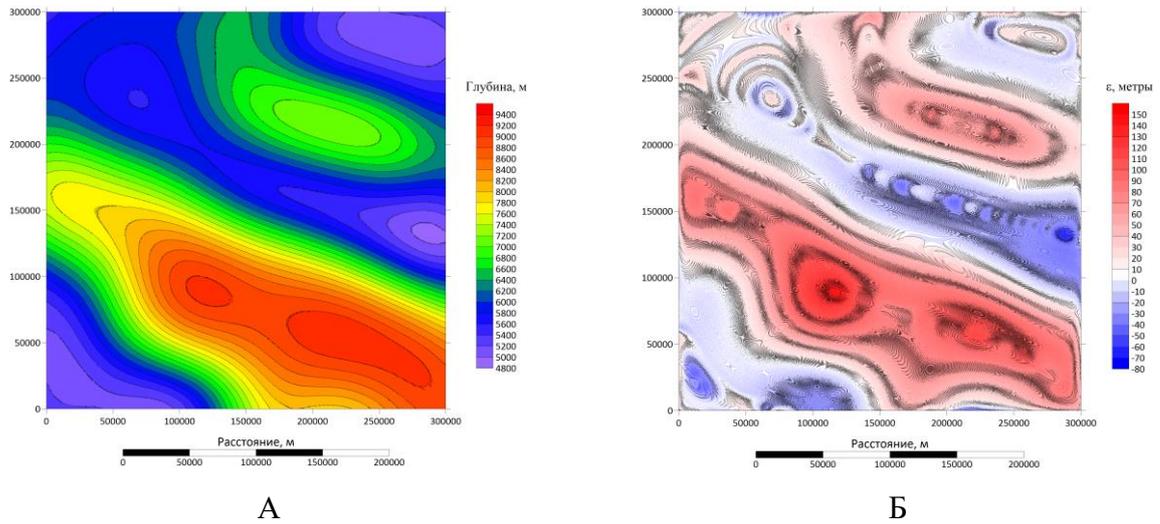


Рисунок 61 – Результат автоматизированного подбора границы в программе GravMagInv3D (А) и его отклонения от истинной модели (Б)

В качестве продолжения эксперимента, к гравитационному полю, использованному для обучения нейронной сети, был добавлен модельный среднечастотный шум. Его амплитуда рассчитывалась с 6 различными уровнями интенсивности: 10%, 15%, 20%, 30%, 40% и 50% от амплитуды изменения исходного гравитационного поля. Шум генерировался как равномерно распределенный в диапазоне от $-A$ до $+A$, где A – соответствующее значение амплитуды, с последующим двукратным усреднением в скользящем окне для придания среднечастотного характера. Структурный горизонт остался без изменения. В качестве обучающего массива использовался структурный горизонт, разреженный по сети профилей через 30 километров. Оценка точности восстановления границы с использованием нейронных сетей приведена в таблице 11.

Таблица 11 Результат работы нейронных сетей для разного зашумления данных

Тип нейронной сети	Количество шума					
	10%	15%	20%	30%	40%	50%
	СКО, м					
1 слой - 100 нейронов	121	150	172	199	260	286
2 слоя - 15 нейронов	118	145	166	189	256	274
10 слоев - 16-32-64-128-256-256-128-64-32-16 нейронов	118	143	162	177	243	268

Результаты для трех нейронных сетей схожи по значениям СКО и по морфологии границ. Ошибка восстановления горизонта при шуме в 50% от амплитуды гравитационного поля увеличилась почти в 3 раза в сравнении со случаем без высокочастотного шума. Результат

применения нейронной сети к гравитационному полю с шумом такого уровня представлен на рисунке 62. Высокочастотная составляющая горизонта, полученного с помощью нейронной сети (Рисунок 62Г) в точности повторяет высокочастотную составляющую поля (Рисунок 62Б).

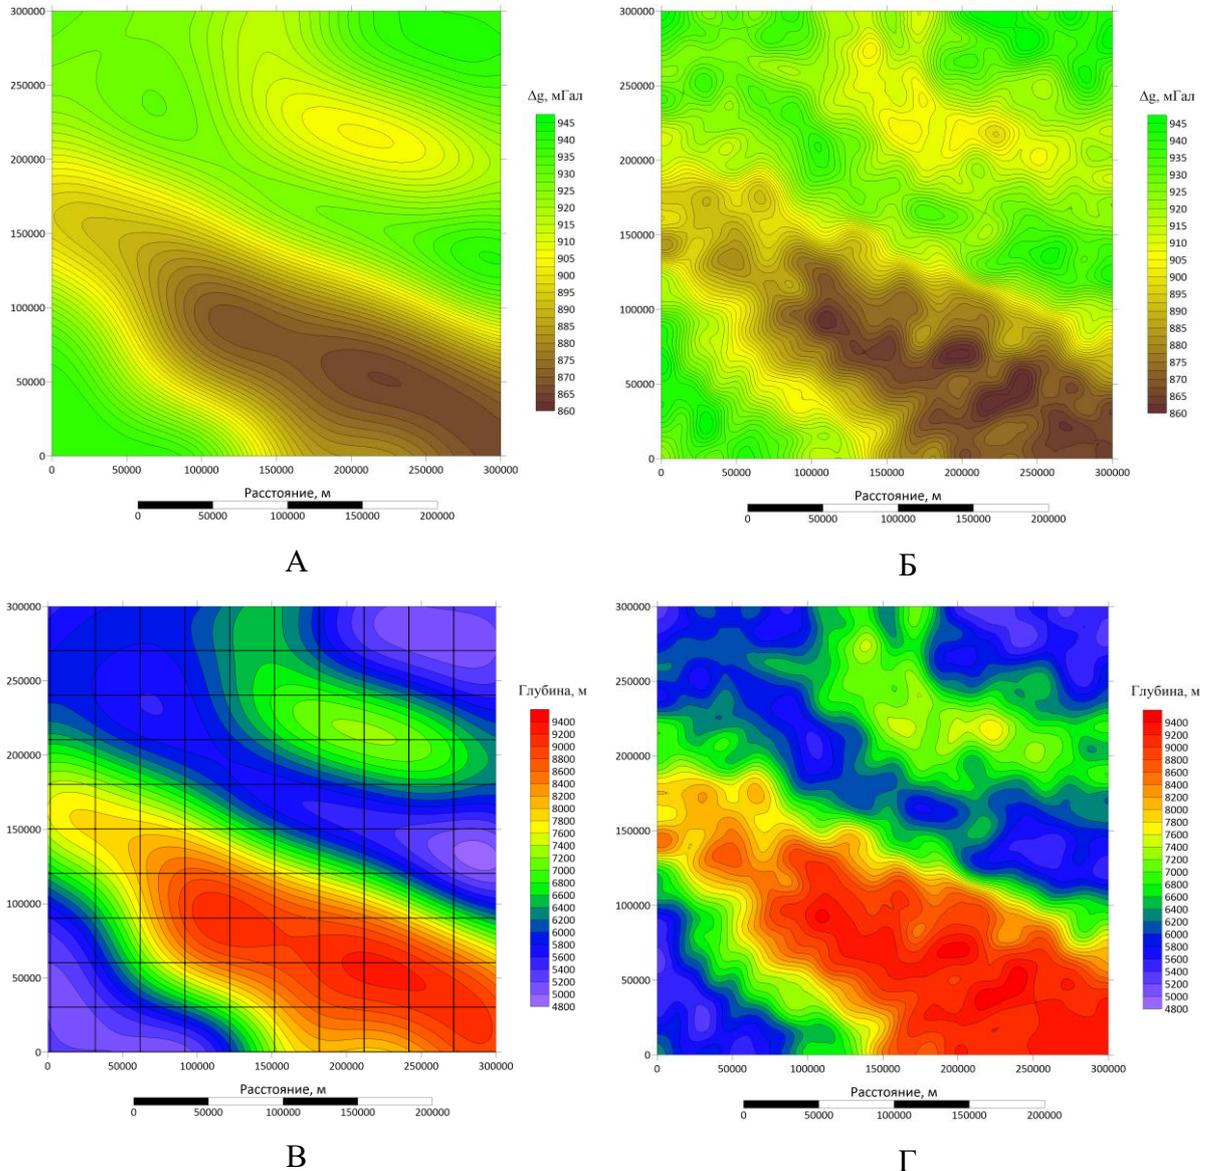


Рисунок 62 – Результат восстановления горизонта по полю с добавленным шумом с помощью нейронной сети:

А – гравитационный эффект структурного горизонта; Б – гравитационный эффект с 50% шумом; В – исходный структурный горизонт с нанесенной сетью профилей с расстоянием 30 км; Г – горизонт, полученный по результатам применения нейронной сети

На рисунке 63 представлена зависимость между глубиной горизонта и значением гравитационного поля. Стоит отметить, что при наличии высокочастотного шума в данных зависимость остается близкой по форме к линейной, однако увеличивается размер

доверительного интервала. Тоже самое можно наблюдать в результатах работы нейронных сетей (Таблица 11).

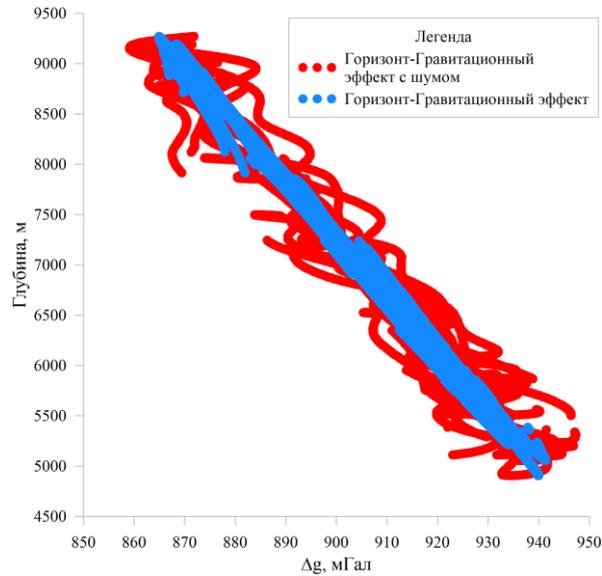


Рисунок 63 – Зависимость между глубиной горизонта и значением гравитационного поля с шумом и без него

Проведенный эксперимент показал, что предложенный метод восстановления горизонта чувствителен к помехам в гравитационном поле. Для уменьшения влияния шумов и повышения качества прогноза в работе были опробованы два подхода: фильтрация итогового горизонта и увеличение объема входных данных с помощью трансформант гравитационного и магнитного полей.

В рамках первого подхода выполнена низкочастотная фильтрация итогового горизонта, полученного в предыдущем эксперименте, фильтром Баттерворта с периодом среза 80 км (Рисунок 64Б). СКО составило ± 176 метров.

Наиболее эффективным оказался второй подход – расширение состава входных параметров. На вход сети подавался не однопараметрические данные о гравитационном поле в точке, а целый вектор признаков, включающий исходное значение поля и 12 его трансформант: результаты низкочастотной фильтрации (фильтр Баттерворта) с периодами среза 70, 80, 90, 100, 125 и 150 км, а также результаты высокочастотной фильтрации с теми же периодами среза (Рисунок 65).

СКО для десятислойной нейронной сети при таком подходе составило ± 74 метра (Рисунок 64В). Использование в обучающей выборке трансформант исходного зашумленного поля позволило улучшить результат в 4 раза, превзойдя точность при обучении на полном наборе данных без зашумления. Этот эффект объясняется тем, что дополнительные трансформанты

позволили сети выделить наиболее информативные и устойчивые к шуму компоненты поля. Высокочастотные фильтры подавили случайные помехи, а низкочастотные – подчеркнули структурную связь аномалии с глубиной горизонта, что в итоге компенсировало недостаток данных и повысило общую устойчивость модели.

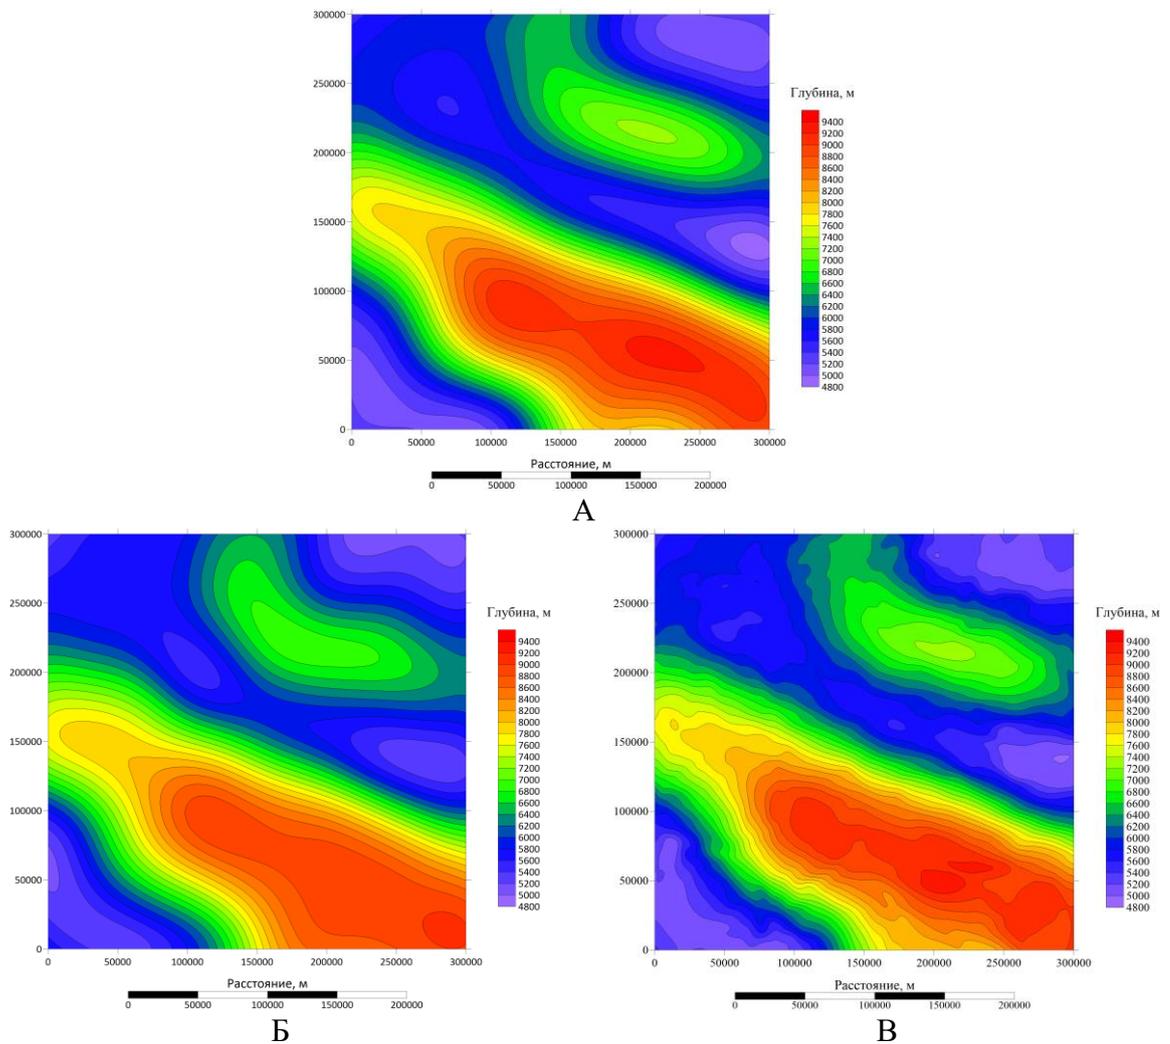


Рисунок 64 – Сравнение различных результатов восстановления горизонта:

А – исходный; Б – по результатам сглаживания (ФНЧ 80 км); В – по результатам нейронной сети с применением трансформант гравитационного поля

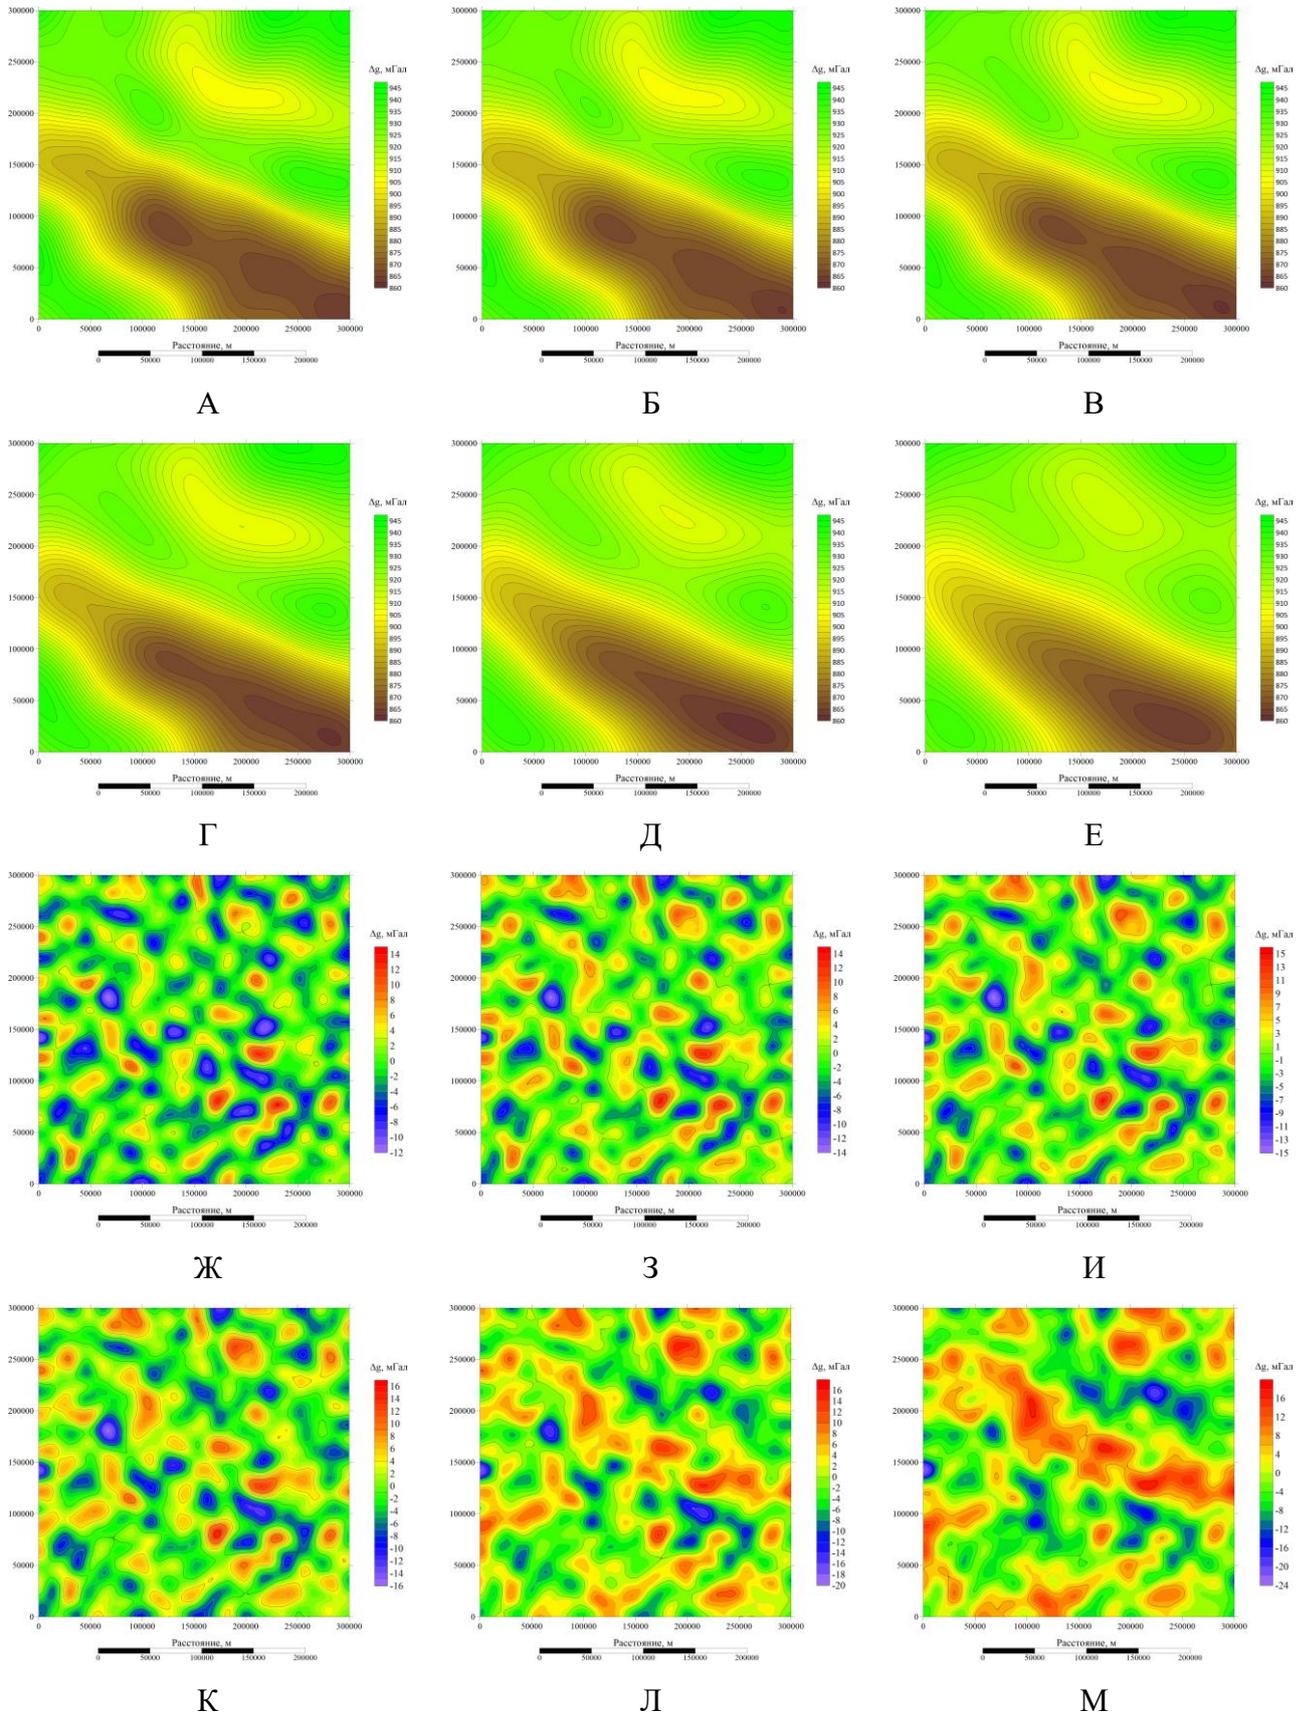


Рисунок 65 – Трансформации гравитационного поля. Низкочастотные фильтры Баттерворта с периодами среза: 70 км (А), 80 км (Б), 90 км (В), 100 км (Г), 125 км (Д) и 150 км (Е); высокочастотные фильтры Баттерворта с периодами среза: 70 км (Ж), 80 км (З), 90 км (И), 100 км (К), 125 (Л) и 150 км (М)

5.3. Применение нейронных сетей в качестве метода для восстановления нескольких плотностных границ на реальных данных

Как отмечалось в предыдущих разделах, восстановление морфологии структурных поверхностей по геофизическим данным представляет собой сложную задачу, требующую комплексного подхода. Различные подходы к описанию регрессионных зависимостей могут описывать не только однопараметрические связи, а применяться к многопараметрическим (многомерным) векторам. В частности, можно построить методы восстановления не одной структурной поверхности, а сразу нескольких.

Рассмотрим в качестве примера задачу построения трех структурных горизонтов (горизонты «1», «2» и «3») на площади с известным распределением аномальных гравитационного и магнитного полей (Рисунок ббА, Б).

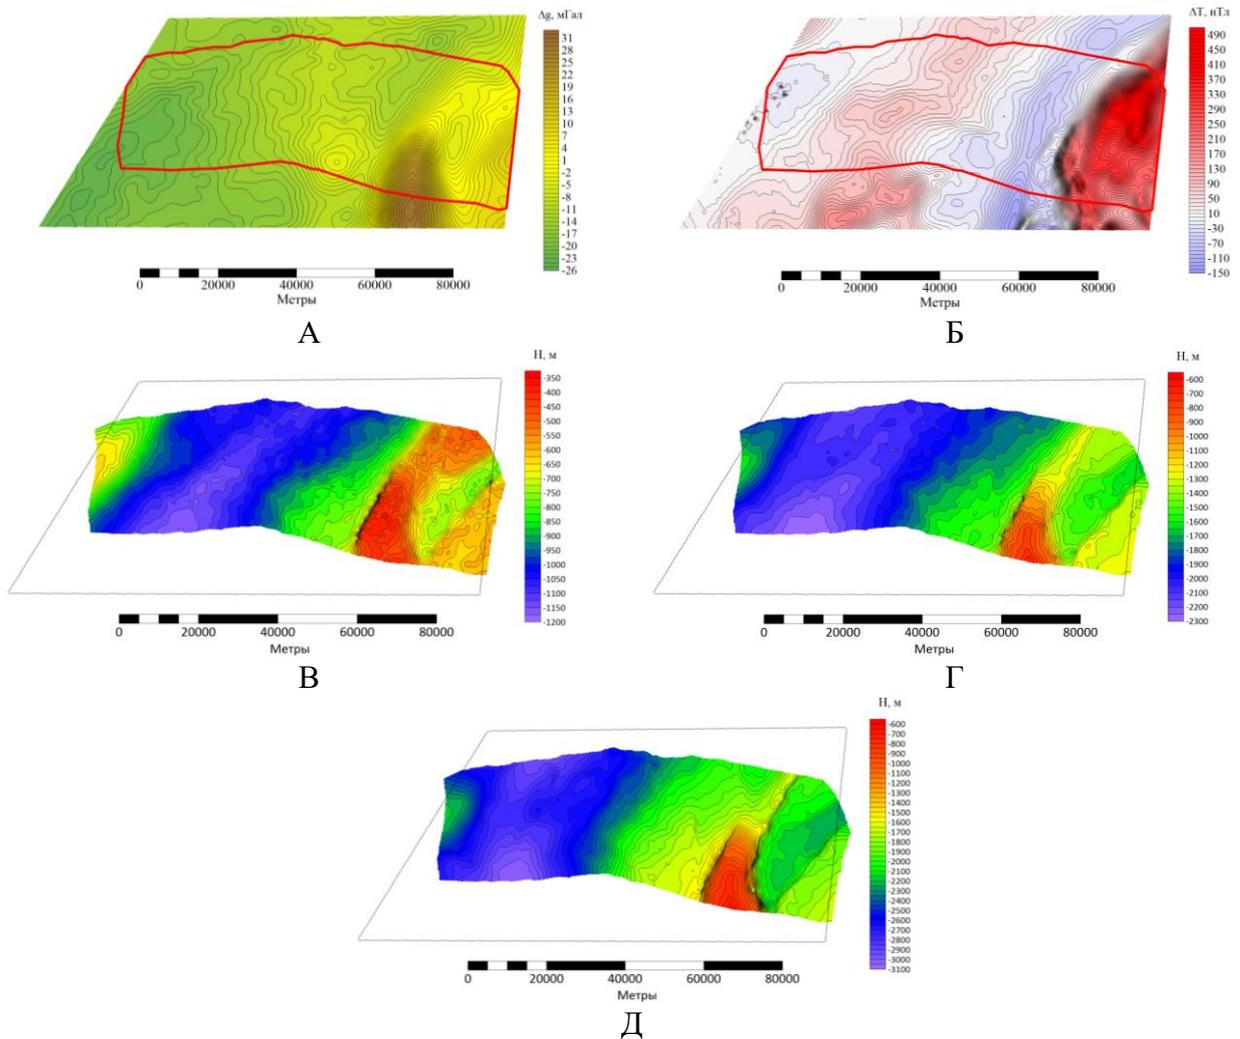


Рисунок бб – Исходные данные:

А – аномальное гравитационное поле; Б – аномальное магнитное поле; В – структурный горизонт «1»; Г – структурный горизонт «2»; Д – структурный горизонт «3»

В качестве обучающей выборки используются данные, полученные в результате интерпретации материалов сейсморазведки (Рисунок 66В-Д). Средние глубины горизонта «1» составляют 850 метров, горизонта «2» – 1730 метров, горизонта «3» – 2180 метров, а перепады глубин составляют от 350 до 1180 метров для горизонта «1», от 670 до 2290 метров для «2», от 670 до 3040 метров для «3» соответственно. Наряду с самими потенциальными полями, как показано в разделе 5.2, возможно использовать их трансформанты, такие как результаты пересчета в верхнее полупространство, производные полей и результаты полосовой фильтрации. В данном примере рассмотрены гравитационное поле и его трансформанты (Рисунок 67А-И): высокочастотные (ВЧ) фильтры Баттерворта 10, 15 и 20 км; низкочастотные (НЧ) фильтры Баттерворта 10, 20 и 30 км; пересчет в верхнее полупространство на 5 и 10 км; разница между суммарным полем и полем, пересчитанным вверх на 10 км, и магнитное поле и его трансформанты (Рисунок 67К) – ВЧ фильтр Баттерворта 5 км; низкочастотные (НЧ) фильтры Баттерворта 10 и 30 км.

В данном разделе представлены результаты комплексного исследования по восстановлению структурных границ с использованием различных современных методов машинного обучения. Наряду с нейронными сетями, рассмотренными в работе выше, для сравнения были выбраны шесть методов:

1. *Метод случайного леса* (Random Forest), предложенный Брейманом [Breiman, 2001], представляющий собой ансамбль (множество) решающих деревьев. В случае регрессии результатом является среднее значение предсказаний отдельных деревьев. Каждое дерево в лесе обучается на случайной подвыборке данных с использованием случайного подмножества признаков. Это позволяет снизить корреляцию между деревьями и уменьшить дисперсию модели.

2. *Градиентный бустинг* (Gradient Boosting) [Friedman, 2001] – ансамблевый метод, который последовательно строит деревья решений, где каждое новое дерево минимизирует остаточные ошибки предыдущих деревьев с помощью градиентного спуска.

3. *Экстремальный градиентный бустинг* (XGBoost) [Chen, Guestrin, 2016] – представляет собой оптимизированную реализацию градиентного бустинга, отличающуюся повышенной вычислительной эффективностью и точностью. Алгоритм последовательно строит ансамбль решающих деревьев, где каждое последующее дерево корректирует ошибки предыдущих. Ключевые преимущества включают использование L_1 и L_2 регуляризации для снижения возможности к переобучению, эффективной обработки пропущенных данных, автоматического отбора признаков, то есть определения и использования наиболее значимых геофизических полей и их трансформант для прогноза, что позволяет упростить модель и повысить её интерпретируемость.

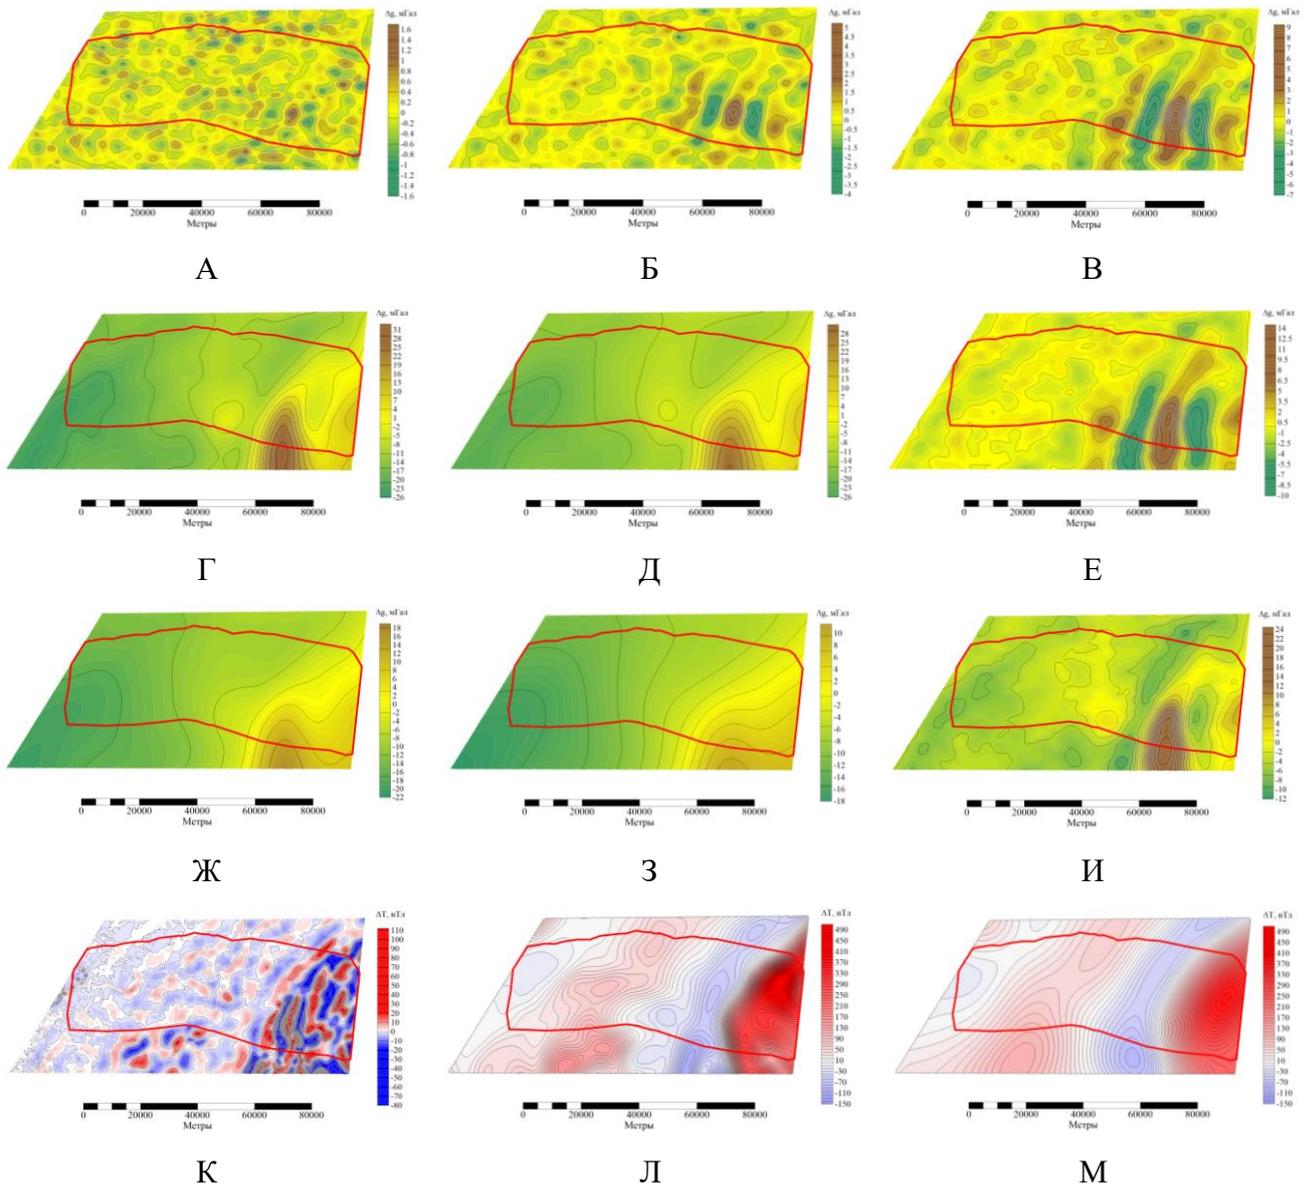


Рисунок 67 – Трансформанты аномальных гравитационного и магнитного полей, использованные для восстановления горизонтов. Гравитационное поле: ВЧ фильтры Баттерворта 10 (А), 15 (Б) и 20 км (В); НЧ фильтры Баттерворта 10 (Г), 20 (Д), 30 км (Е); пересчет в верхнее полупространство на 5 (Ж) и 10 км (З); разница между исходным полем и полем, пересчитанным вверх на 10 км (И). Магнитное поле: ВЧ фильтр Баттерворта 5 км (К); НЧ фильтры Баттерворта 10 (Л) и 30 км (М)

4. Регрессия с регуляризацией по Тихонову (Ridge Regression) [Hoerl, Kennard, 1970] – это модификация линейной регрессии с L_2 регуляризацией, которая добавляет штраф за большие значения коэффициентов регрессии. Это позволяет уменьшить дисперсию модели и улучшить ее обобщающую способность, особенно при наличии высокой корреляции входными и выходными данными.

5. *Метод опорных векторов* (Support Vector Regression, SVR) [Smola, Schölkopf, 2004] – это алгоритм машинного обучения, специально разработанный для решения задач прогнозирования непрерывных величин. Ключевая особенность метода опорных векторов заключается в минимизации обобщенной ошибки с использованием ϵ -нечувствительной функции потерь. Параметр ϵ задает допустимый порог отклонения: для каждого наблюдения штраф начисляется только в случае, если отклонение прогноза от истинного значения превышает ϵ . Такой подход делает алгоритм робастным к выбросам и шуму в данных. Сложность модели регулируется параметром регуляризации, который ограничивает весовые коэффициенты, обеспечивая устойчивость к переобучению. Метод опорных векторов особенно эффективно работает с многомерными данными и в ситуациях, когда количество признаков превышает число наблюдений.

6. *Метод ближайших соседей* (KNN) [Cover, Hart, 1967] – это непараметрический алгоритм, который предсказывает значение целевой переменной как среднее (для регрессии) значений k ближайших соседей в пространстве признаков.

Перед применением методов машинного обучения для построения регрессионных моделей был проведен корреляционный анализ с целью оценки информативности признаков и выявления сильнокоррелированных параметров. Анализ матрицы корреляций (Рисунок 68) выявил существенные различия во взаимосвязях между геофизическими полями и структурными горизонтами. Установлено, что наибольшие коэффициенты линейной корреляции Пирсона (0.76-0.89) наблюдаются между низкочастотными гравитационными трансформантами (результаты ФНЧ-фильтрации и пересчета в верхнее полупространство) и горизонтами «1»-«3». В то же время, магнитное поле демонстрирует слабую линейную связь с целевыми переменными (коэффициент до 0.34), особенно с горизонтом «3» (0.048).

Полученные результаты позволили оценить потенциальную значимость различных геофизических признаков для решения поставленной задачи. Кроме того, выявленные низкие значения корреляции для части признаков указывают на наличие более сложных, нелинейных зависимостей, которые не могут быть описаны линейными методами. Это стало важным обоснованием для применения таких методов машинного обучения, как градиентный бустинг и нейронные сети, способных эффективно выявлять и аппроксимировать сложные нелинейные взаимосвязи в данных.

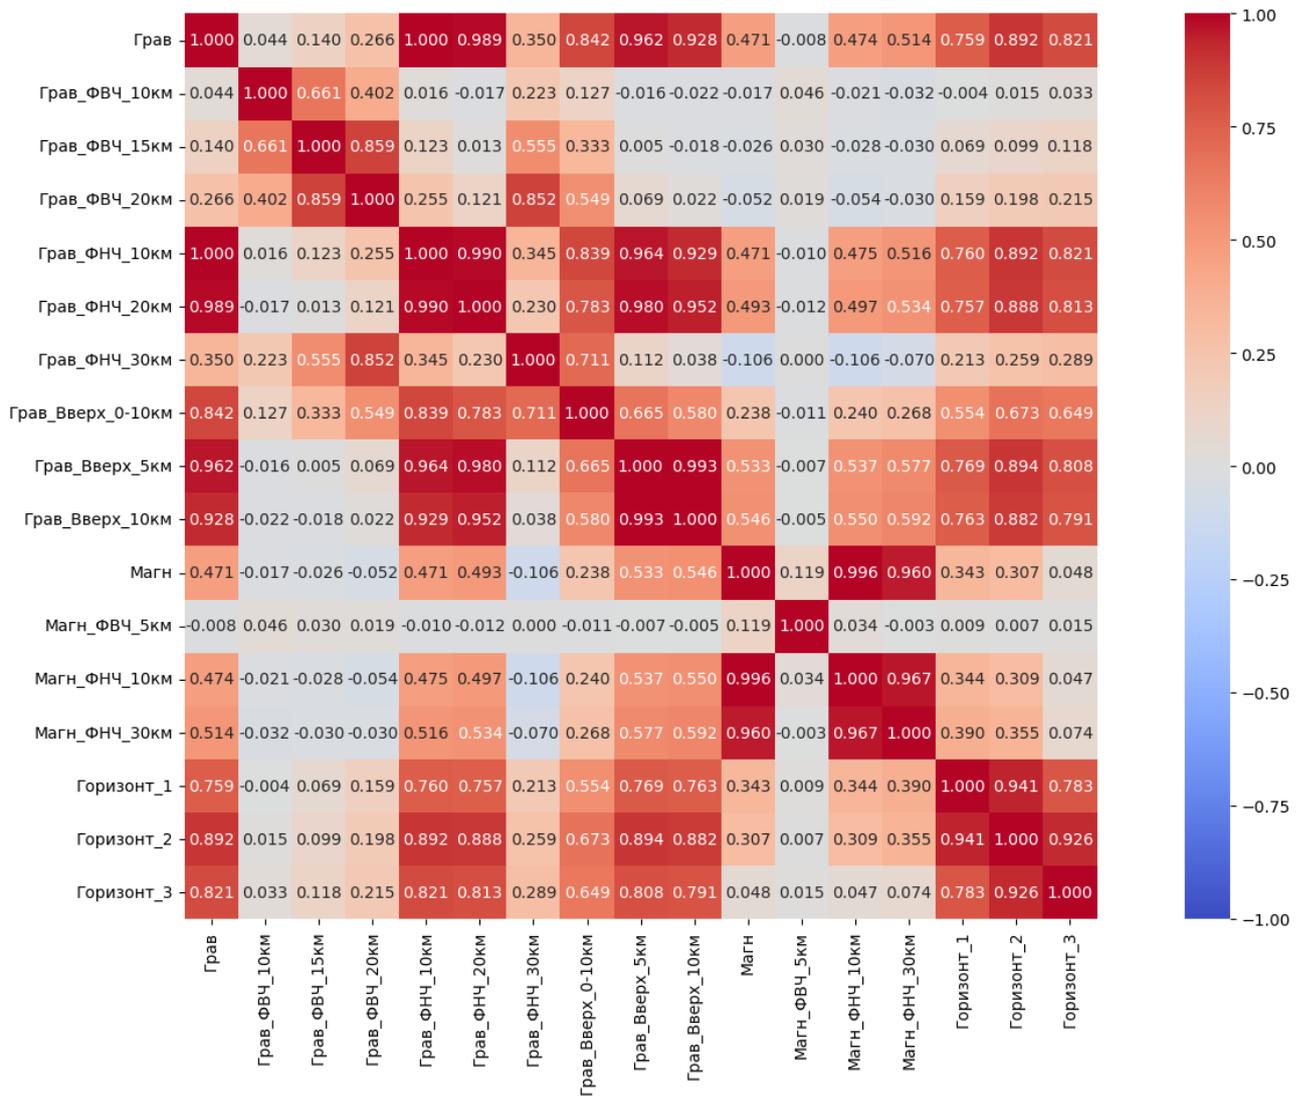


Рисунок 68 – Матрица корреляции геофизических полей и горизонтов

5.3.1. Валидация на полных данных и экстраполяция за границы обучения

Первый эксперимент был направлен на оценку точности описанных методов при восстановлении границ по полному набору данных.

Для построения регрессионных зависимостей и обучения нейронных сетей использовано 54 627 точек, для восстановления – 91 343 точек, шаг между точками – 250 метров.

В ходе работы рассмотрено несколько конфигураций нейронных сетей. Наилучший результат достигнут с использованием пятислойной архитектуры с последовательным изменением количества нейронов по слоям: 64, 128, 256, 128, 64.

Обучение нейронных сетей проводилось со следующими параметрами:

- оптимизатор: Adam с скоростью обучения 0.001;
- функция потерь: среднеквадратическая ошибка (MSE);

- метрика оценки: среднеквадратичное отклонение (СКО/RMSE) для каждого горизонта;
- размер пакета данных (batch size): 32;
- количество эпох: 500;
- стратегия валидации: разделение исходной выборки в соотношении 80/20 на обучающую и проверочную подвыборки;
- предобработка данных: стандартизация (StandardScaler) для всех входных признаков.

Для решения задачи одновременного восстановления нескольких структурных горизонтов использовалась архитектура с несколькими выходными слоями, где каждый выходной слой соответствовал прогнозируемой глубине одного целевого горизонта.

Результаты представлены в таблице 12. Для горизонта «1» наилучшие результаты получены алгоритмом случайный лес со среднеквадратическим отклонением от исходного ± 2.2 метра и методом к-ближайших соседей с СКО ± 5 метров, в то время как худший результат получен с помощью регрессии с регуляризацией по Тихонову – ± 129 метров. Аналогичная картина наблюдалась и для других горизонтов: на горизонте «2» точность случайного леса – ± 2.3 м, а метод ближайших соседей – ± 6 метра. Особенно показательны результаты для горизонта «3», где помимо случайного леса (СКО ± 3.8 м) хорошую точность показала нейронная сеть (СКО ± 10 м).

Важно отметить, что результат линейного метода регрессии с регуляризацией по Тихонову имеет наихудшую точность восстановления для всех горизонтов, что свидетельствует о его непригодности для решения подобных нелинейных задач. Интересно отметить, что метод опорных векторов показал низкую точность (СКО $\pm 71-157$ м), что может быть связано с особенностями геофизических данных.

Таблица 12 Оценка среднеквадратического отклонения (СКО) восстановленных горизонтов от исходных для различных методов машинного обучения (в метрах)

	Случ. лес	Экс. град. бустинг	Регрессия с регул. по Тихонову	Град. бустинг	Метод опорных векторов	Метод ближ. соседей	Нейронная сеть
Горизонт «1»	2.2	10	129	32	71	5	7
Горизонт «2»	2.3	15	124	43	87	6	8
Горизонт «3»	3.8	23	160	64	157	10	10

Хотя анализ среднеквадратичных отклонений (СКО) дает важную количественную оценку точности различных методов, для полного понимания их эффективности необходимо

выполнить качественный анализ морфологии восстановленных горизонтов. При переходе от численных оценок к визуальной выявляются ключевые особенности, которые не отражаются в статистических метриках. На рисунке 69 представлены результаты работы 7 методов восстановления горизонта «1».

В результатах применения алгоритмов случайный лес и метод ближайших соседей при экстраполяции наблюдаются артефакты, резкие перепады значений глубин горизонта. Метод регрессии с регуляризацией по Тихонову, несмотря на худшую точность восстановления, показал хороший визуальный результат экстраполяции данных, но только на региональном уровне (граница гладкая и не содержит высокочастотных аномалий). Нейронные сети дают более точные результаты при прогнозировании данных за пределами обучающей выборки. В отличие от других методов, переход между известными и прогнозируемыми значениями получается практически незаметным.

Первый эксперимент по валидации на полных данных выявил определенную закономерность. Традиционные методы машинного обучения, такие как случайный лес, метод ближайших соседей и экстремальный градиентный бустинг, демонстрируют превосходную точность при работе с данными, на которых они обучались, показывая среднеквадратичные отклонения всего $\pm 2-23$ метра. Однако при попытке экстраполяции на новые участки эти методы дают физически необоснованные результаты – восстановленные поля содержат артефакты и резкие градиенты в рельефе горизонтов.

Нейронные сети, хотя и уступают в точности при оценке по обучающей выборке (СКО $\pm 7-10$ метров), показывают значительно более гладкие результаты при экстраполяции. Это особенно заметно на границе участка.

Наблюдаемые различия обусловлены принципиально разными подходами к обобщению данных. Такие методы, как случайный лес, метод ближайших соседей и экстремальный градиентный бустинг, эффективно запоминают и интерполируют закономерности в пределах обучающей выборки, но демонстрируют ограниченную способность к экстраполяции – переносу выявленных зависимостей на новые, неизвестные области. В отличие от них, нейронные сети за счет многослойной структуры и распределенного представления признаков способны выявлять более глубокие и устойчивые закономерности, что обеспечивает их лучшую предсказательную способность за границами обученной области.

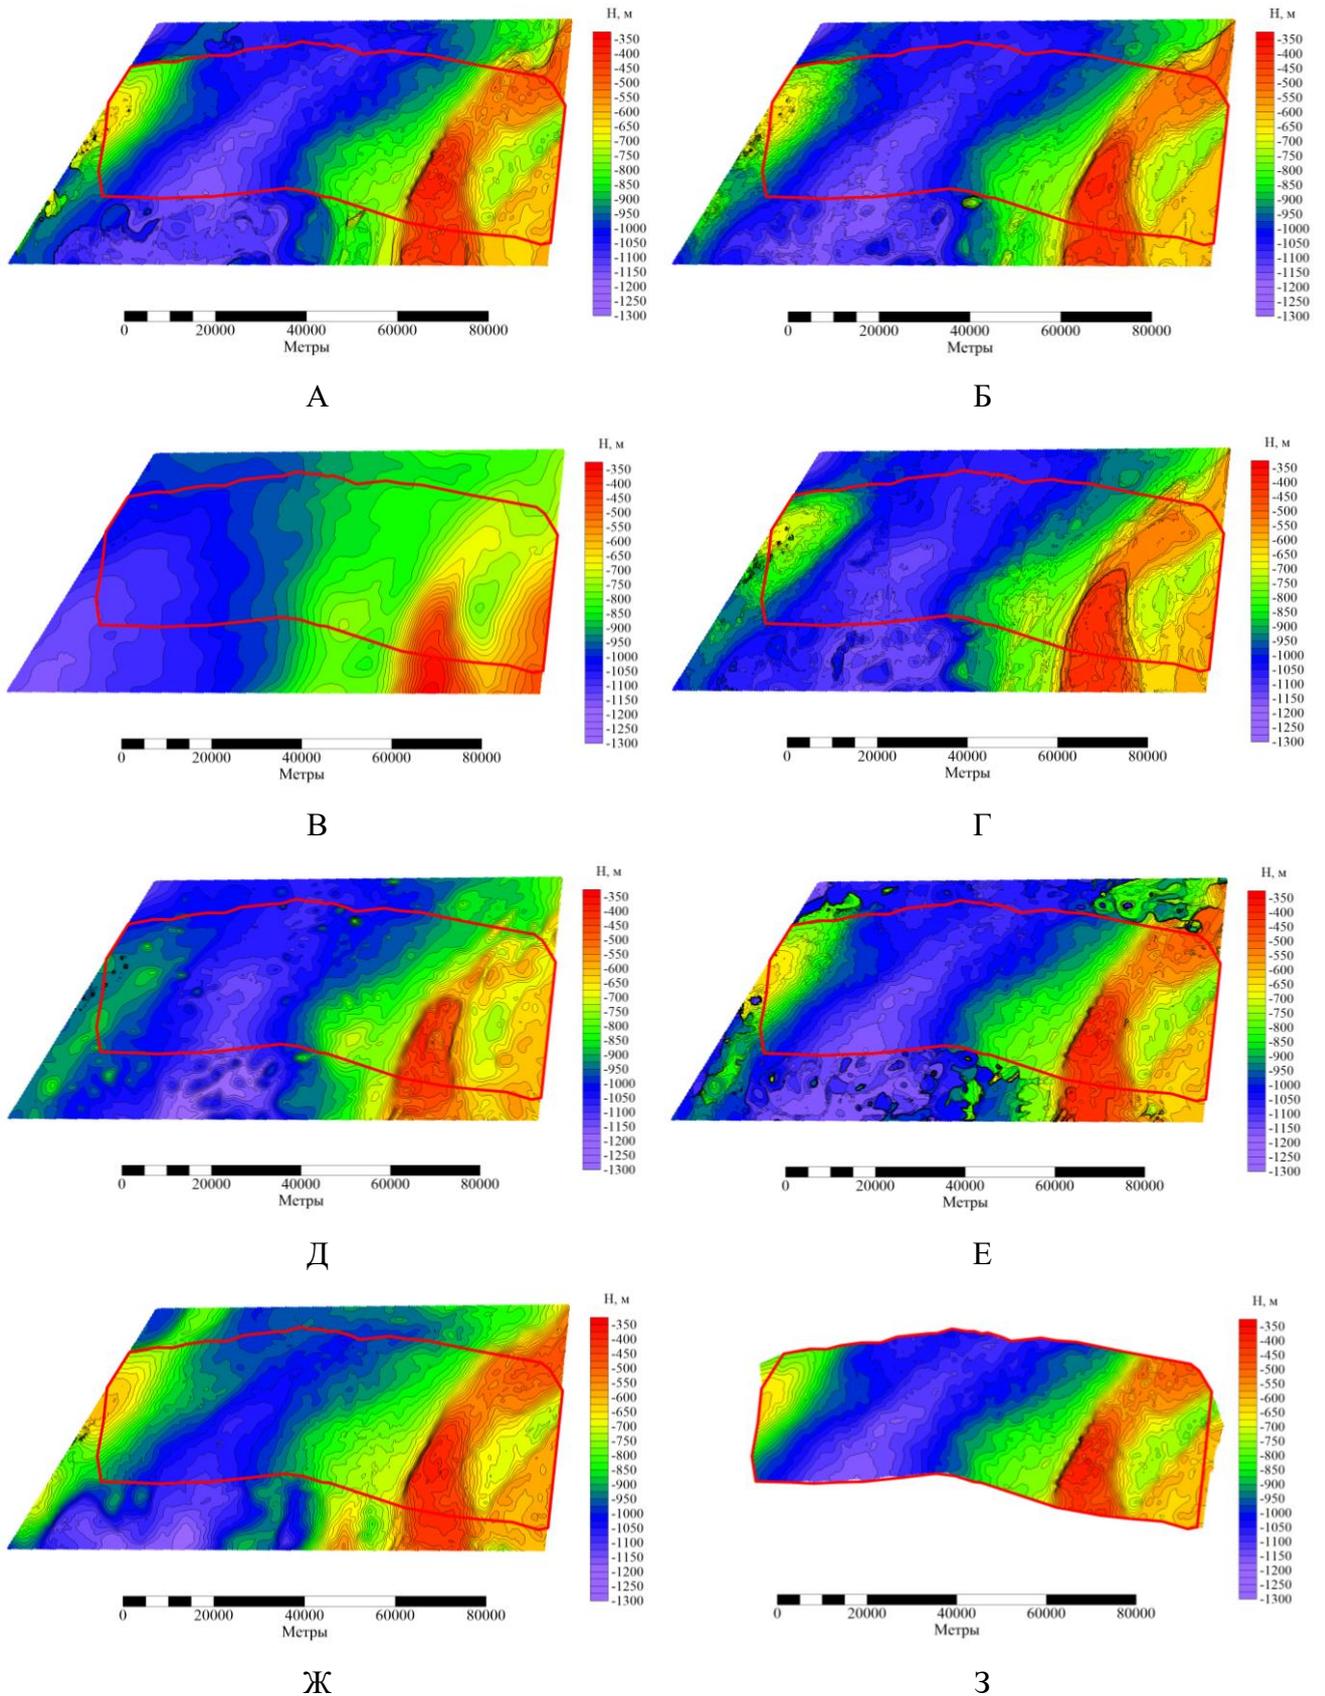


Рисунок 69 – Результаты восстановления горизонта «1» методами: А – Случайный лес; Б – Экстремальный градиентный бустинг; В – Регрессия с регуляризацией по Тихонову; Г – Градиентный бустинг; Д – Метод опорных векторов; Е – Метод ближайших соседей; Ж – Нейронная сеть; З – Исходный горизонт

5.3.2. Интерполяция данных внутри обучающей выборки

Второй эксперимент посвящен оценке способности методов к интерполяции. Для этого из исходных данных исключены два прямоугольных участка общей площадью около 18% от площади исследования. Обучение проводилось на оставшихся 82% данных (Рисунок 70), а оценка точности по исключенным зонам.

Все результаты сведены в таблицу с среднеквадратическими ошибками для каждого метода (Таблица 13). Эксперимент по интерполяции выявил различия в эффективности методов машинного обучения. Нейронная сеть продемонстрировала лучшие показатели среди всех рассматриваемых методов – СКО составило ± 36 м для горизонта «1», ± 28 м для горизонта «2» и ± 71 м для горизонта «3». Эти результаты особенно выделяются на фоне других методов: градиентный бустинг, занявший второе место для горизонта «1» (± 57 м), уступил нейросети более чем на 20 метров, а для глубинных горизонтов разрыв стал еще более значительным.

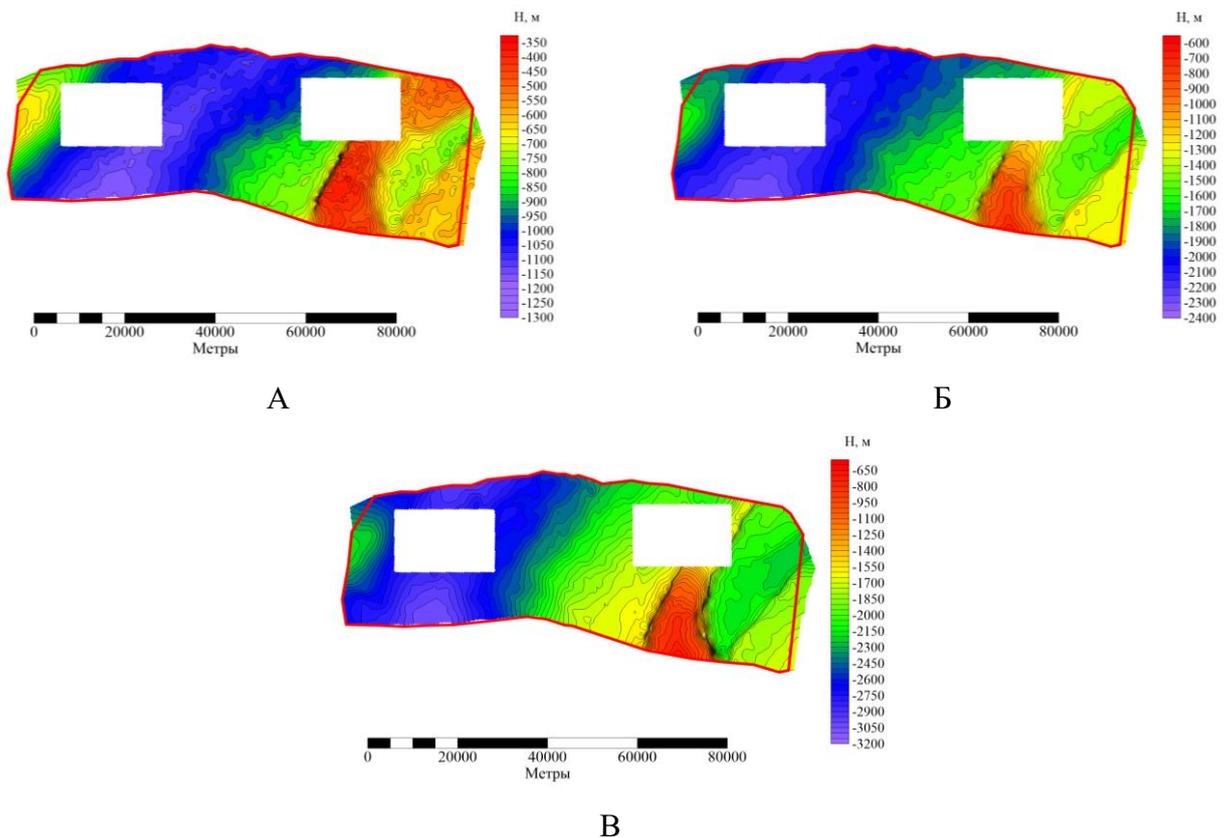


Рисунок 70 – Горизонты с исключенными участками: А – «1»; Б – «2»; В – «3»

Таблица 13 Оценка среднеквадратического отклонения (СКО) восстановленных горизонтов от исходных для различных методов машинного обучения (в метрах) на исключенных из обучающей выборки участках

	Случ. лес	Экс. град. бустинг	Регрес. с регул. по Тихонову	Град. бустинг	Метод опорных векторов	Метод ближ. соседей	Нейронная сеть
Горизонт «1»	68	68	100	57	69	85	37
Горизонт «2»	74	65	80	76	62	93	28
Горизонт «3»	145	117	96	116	106	129	71

Важно отметить ухудшение результатов для методов, которые показали наилучший СКО в первом эксперименте (Раздел 5.3.1). Случайный лес, показавший ранее лучшие результаты ($\pm 2-4$ м), при интерполяции позволил восстановить горизонты лишь с точностью от ± 68 до ± 145 м. Аналогичная ситуация и с методом ближайших соседей – отличные показатели на обучающей выборке ($\pm 5-10$ м) сменились падением точности ($\pm 85-129$ м) при интерполяции. Это подтверждает, что данные методы не позволяют корректно восстановить горизонты за пределами зон с исходными данными, а их результаты содержат артефакты и разрывы.

Из остальных методов корректные результаты показали экстремальный градиентный бустинг ($\pm 65-117$ м) и метод опорных векторов ($\pm 62-106$ м), однако они значительно уступают нейронным сетям, особенно для глубинных горизонтов.

5.3.3. Экстраполяция данных за границы обучающей выборки

Третий эксперимент направлен на оценку одного из наиболее сложных и практически значимых сценариев – способности методов к экстраполяции, то есть прогнозированию значений за пределами области, охваченной обучающей выборкой. В реальных геофизических исследованиях часто возникает необходимость прогнозирования структур за пределами районов с детальной сейсмической съемкой, что требует от методов умения обобщать закономерности и переносить их на новые, неизученные территории.

Для моделирования данной ситуации из исходной обучающей выборки исключен протяженный участок в верхней (северной) части карты, составляющий 28% от общей площади исследования (Рисунок 71). Обучение всех методов проводилось на оставшихся 72% данных, а итоговая оценка точности выполнялась исключительно на вырезанном участке, который методы ранее не учитывали.

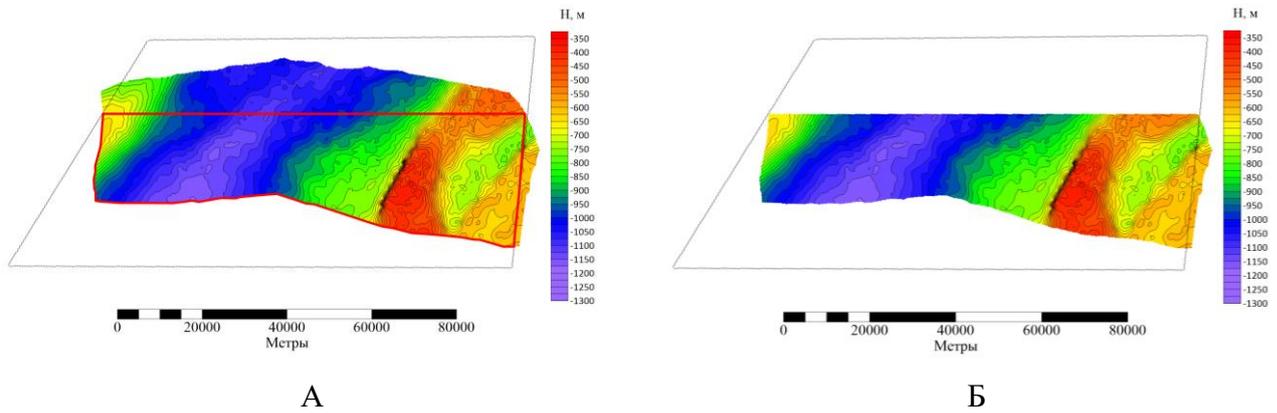


Рисунок 71 – Подготовленные данные для эксперимента по экстраполяции данных с помощью методов машинного обучения: А – исходный горизонт «1»; Б – горизонт для обучающей выборки

Результаты эксперимента представлены в таблице 14. Наилучший результат получен с применением нейронной сети – СКО ± 48 м, ± 63 м и ± 107 м для горизонтов «1», «2» и «3» соответственно. Ошибка оказалась систематически ниже, чем у других методов: особенно заметно превосходство для первых двух горизонтов. Среди остальных методов относительно хорошую устойчивость восстановления показали экстремальный градиентный бустинг и градиентный бустинг, однако их ошибка была на 20-40% выше, чем у нейронной сети. Методы, показавшие лучшие результаты на полных данных (случайный лес, метод ближайших соседей), в условиях экстраполяции продемонстрировали значительное падение точности, а регрессия с регуляризацией по Тихонову и метод опорных векторов стабильно показали наихудшие результаты.

Таблица 14 Оценка среднеквадратического отклонения (СКО) восстановленных горизонтов от исходных для различных методов машинного обучения (в метрах) на исключенном из обучающей выборки участке

	Случ. лес	Экс. град. бустинг	Регрес. с регул. по Тихонову	Град. бустинг	Метод опорных векторов	Метод ближ. соседей	Нейронная сеть
Горизонт «1»	70	66	151	71	116	97	48
Горизонт «2»	99	88	135	74	114	108	63
Горизонт «3»	128	121	157	115	154	143	107

Данный эксперимент наглядно демонстрирует, что нейронные сети обладают наивысшей способностью к обобщению выявленных зависимостей и генерации физически обоснованных

результатов в условиях дефицита априорной информации, что делает их наиболее предпочтительным инструментом для прогнозного построения структурных границ на плохо изученных территориях.

5.3.4. Интерполяция данных при различной степени разрежения

Четвертый эксперимент специально разработан для оценки важного для практики параметра – устойчивости методов к различной степени разрежения входных данных. В реальных геофизических исследованиях часто приходится работать с неравномерной сеткой наблюдений или ограниченным количеством профилей, поэтому понимание поведения методов в таких условиях имеет принципиальное значение. В эксперименте, моделирующем типичные полевые ситуации от детальных исследований до региональных съемок, плотность данных последовательно уменьшалась в 3, 5, 10, 20 и 50 раз.

Результаты выявили несколько ключевых закономерностей (Таблица 15). На начальных стадиях разрежения (в 3-5 раз) нейронная сеть показала наибольшую устойчивость. Ее точность ухудшилась всего на 30-50% при пятикратном уменьшении плотности данных, тогда как случайный лес и метод ближайших соседей потеряли в точности в 2-3 раза. Это особенно заметно на примере горизонта «1», где при разрежении в 5 раз нейронная сеть (± 12.8 м) практически соответствует по точности метода случайного леса (± 8.9 м), который показал наилучшие результаты на полном объеме данных. Еще более показательная ситуация складывается для горизонта «3» – здесь при разрежении в 10 раз нейронная сеть (± 27 м) выходит на первое место, обходя все традиционные методы по точности восстановления границ.

При экстремальном разрежении в 50 раз картина несколько меняется. Результаты экстремального градиентного бустинга имеют лучшую устойчивость для горизонтов «1» и «2» (± 52 и ± 72 м соответственно), в то время как применение нейронной сети позволяет добиться сопоставимых результатов (± 55 и ± 90 м). Однако для самого глубокого горизонта «3» оба метода дают близкие и относительно высокие значения СКО (± 124 м – экстремальный градиентный бустинг, ± 116 м – нейронная сеть), что свидетельствует о принципиальных сложностях восстановления глубинных структур по редкой сети.

Для качественного анализа рассмотрим прогноз горизонта «3» при разрежении данных в 50 раз. Результаты работы методов представлены на рисунке 72. Отметим, что метод опорных векторов не позволил решить задачу восстановления границы – СКО (± 435 м). Все методы за исключением регрессии с регуляризацией по Тихонову и нейронной сети имеют артефакты и резкие перепады в рельефе горизонтов, что также наблюдалось ранее.

Таблица 15 Оценка среднеквадратического отклонения (СКО) восстановленных горизонтов от исходных для различных методов машинного обучения (в метрах) и различного разрежения данных

	Разреж.	Случ. лес	Экс. град. бустинг	Рег. с регул. по Тихонову	Град. бустинг	Метод опорных векторов	Метод ближ. соседей	Нейронная сеть
Горизонт «1»	x1	2.1	10.2	129	32	71	5.0	7.2
	x3	6.9	11.3	128	33	87	9.1	11.1
	x5	8.9	12.3	129	33	95	12.7	12.8
	x10	14	15.6	129	34	106	20	17.6
	x20	28	28	129	37	118	34	28
	x50	56	52	131	57	141	67	55
Горизонт «2»	x1	2.3	14.6	124	43	87	6.4	8.2
	x3	8.3	15.8	126	43	123	11.8	13.2
	x5	11.6	16.9	126	42	139	16.7	14.6
	x10	20	22	127	45	158	28	21
	x20	37	35	128	48	188	46	40
	x50	71	72	130	74	253	88	90
Горизонт «3»	x1	3.8	23	160	64	157	10.1	10.2
	x3	15.9	26	165	65	224	19.7	16.2
	x5	22	29	167	66	246	29	18.8
	x10	37	38	169	68	290	48	27
	x20	65	62	171	74	360	77	56
	x50	132	124	177	116	435	140	116

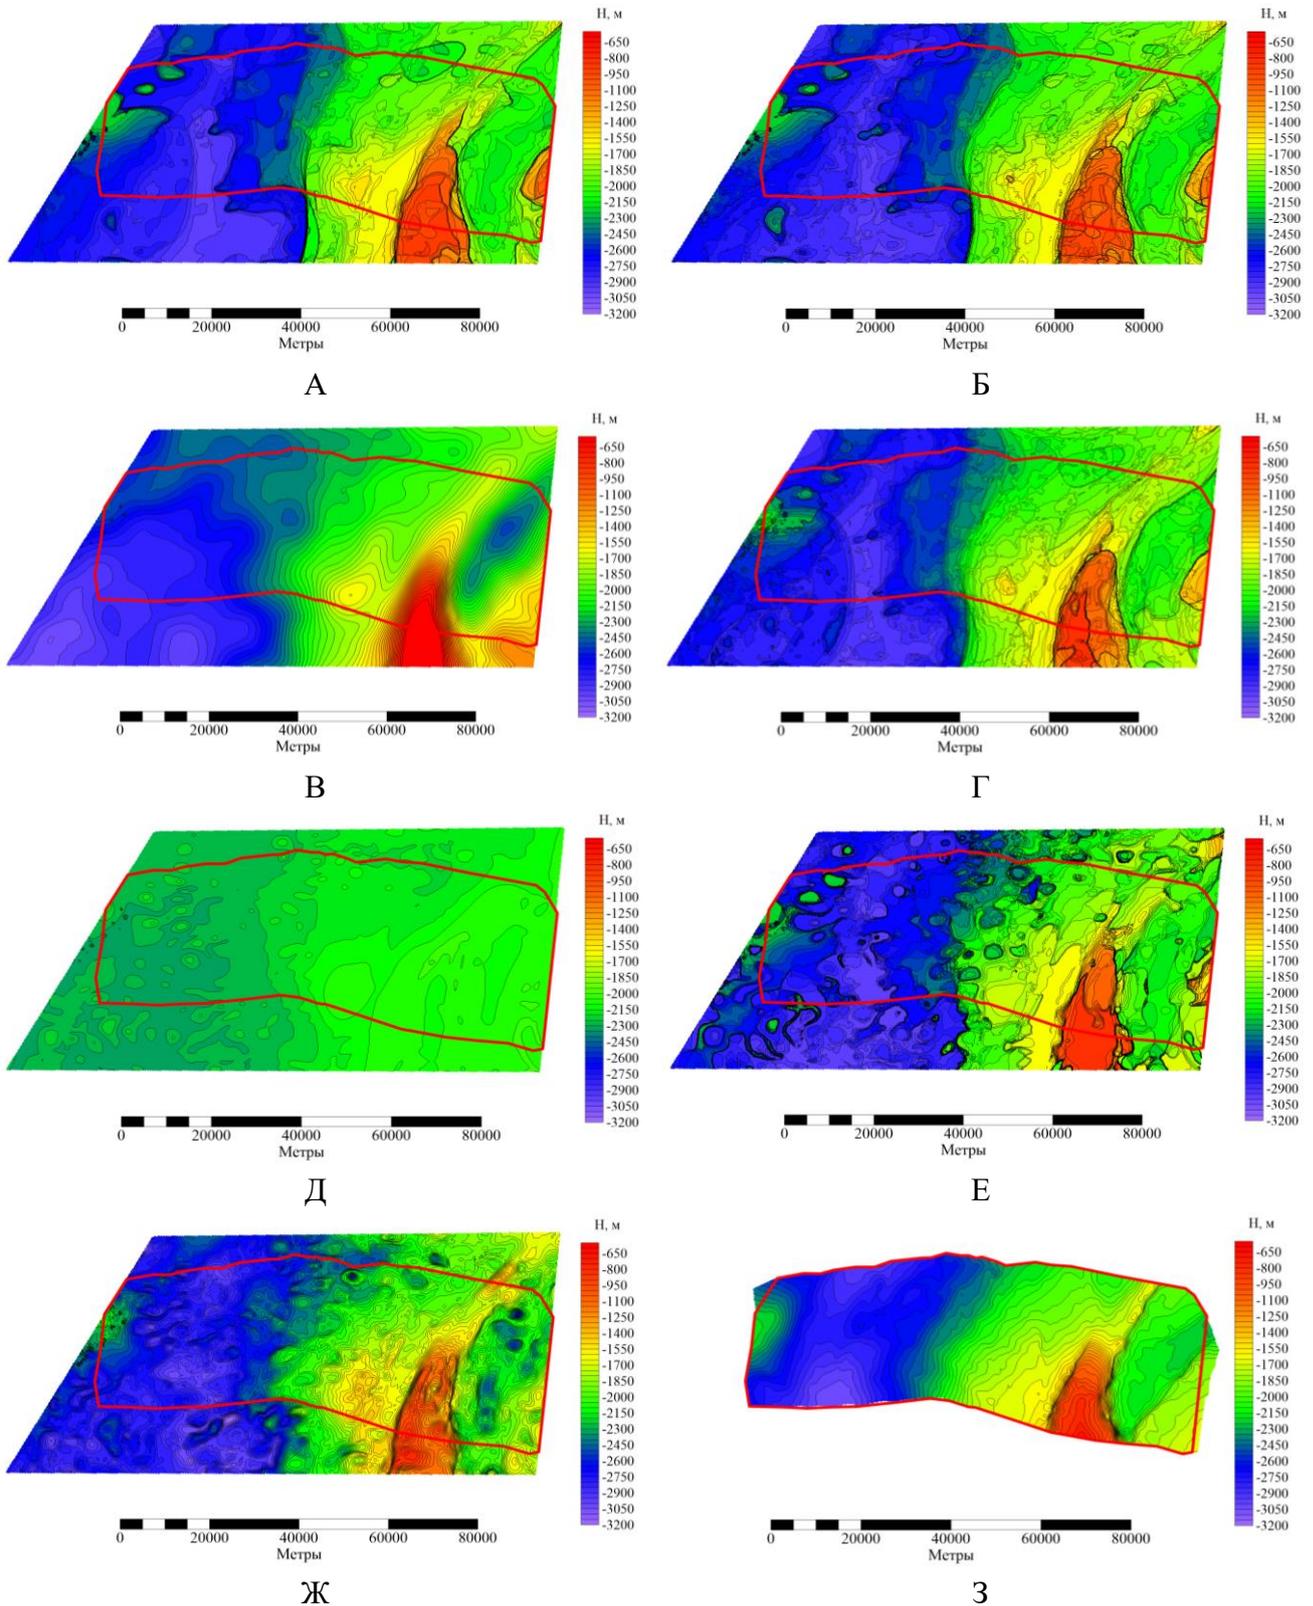


Рисунок 72 – Результаты работы методов машинного обучения для горизонта «3» при разрежении данных в 50 раз: А – Случайный лес; Б – Экстремальный градиентный бустинг; В – Регрессия с регуляризацией по Тихонову; Г – Градиентный бустинг; Д – Метод опорных векторов; Е – Метод ближайших соседей; Ж – Нейронная сеть; З – Исходный горизонт

5.4. Выводы по Главе 5

Проведенные исследования подтвердили эффективность нейронных сетей для восстановления структурных границ по комплексу геофизических данных. На модельном примере показана способность сетей точно (СКО $\sim \pm 100$ м) восстанавливать связь между гравитационным полем и глубиной залегания горизонта. Установлена устойчивость метода к разрежению данных: для надежного восстановления горизонта достаточно информации всего на 5% площади. Эксперименты с зашумленными данными выявили, что добавление в обучающую выборку трансформант полей позволяет повысить точность восстановления границ.

На основе проведенных исследований разработан метод восстановления структурных границ, включающий следующие этапы (Рисунок 73):

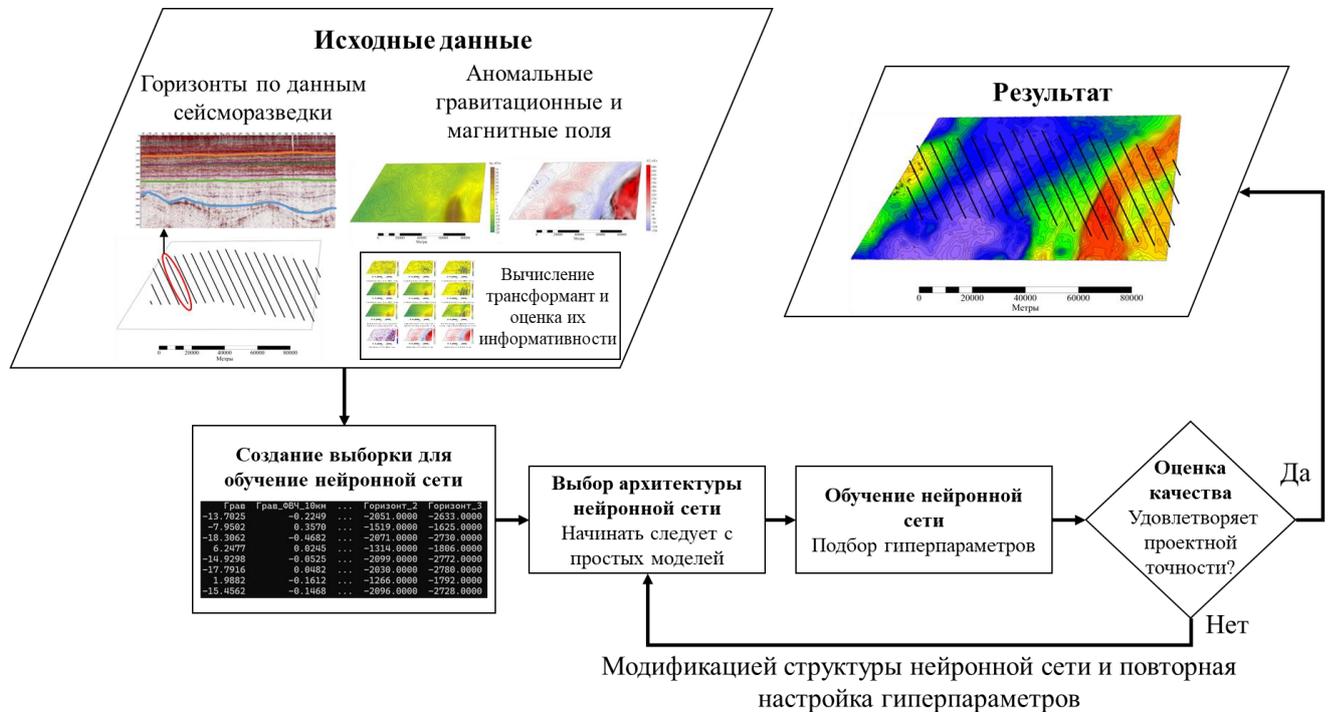


Рисунок 73 – Метод восстановления морфологии структурных границ по аномальным гравитационным и магнитным полям с помощью нейронных сетей

1. Формирование обучающей выборки на основе эталонных участков с известным положением горизонтов (выходные данные). Они могут представлять собой как данные вдоль сети профилей, так и данные на отдельной площади – части участка исследования. В качестве входных данных необходимо использовать аномальные гравитационные и магнитные поля и их трансформанты (ФНЧ, ФВЧ, пересчеты в верхнее полупространство и др.).

2. Выбор архитектуры нейронной сети. Предлагается осуществлять последовательное усложнение архитектуры от простых одно-/двухслойных конфигураций до многослойных сетей

(например, пятислойная архитектура 64-128-256-128-64) для решения конкретных комплексных задач на основе оценки точности, выполняемой на четвертом этапе.

3. Оптимизация параметров обучения нейронной сети, функций потерь (MSE, BCE), метрик качества (Accuracy, Precision, Recall), количества эпох и скорости обучения в зависимости от специфики решаемой геологической задачи и характеристик входных данных.

4. Итеративная оптимизация и валидация модели, включающая комплексную оценку точности на валидационной и тестовой выборках с использованием метрики качества, в первую очередь среднеквадратического отклонения (СКО). При неудовлетворительных результатах предлагается вернуться к начальному этапу выбора архитектуры с последующей модификацией структуры нейронной сети и повторной настройкой гиперпараметров до достижения требуемого качества прогноза как в пределах обучающей выборки, так и при решении задач интерполяции и экстраполяции данных.

Сравнительный анализ с традиционными методами машинного обучения выявил ключевое преимущество нейронных сетей – способность к обобщению. В то время как методы вроде случайного леса показывают лучшую точность на полных данных, их прогноз за пределами обучающей выборки часто является нефизичным. Нейронные сети демонстрируют стабильно высокую точность и геологическую осмысленность результатов во всех сценариях: при интерполяции, экстраполяции и работе с разреженными данными. Разработанный метод подтвердил свою эффективность для решения практических задач, позволяя надежно восстанавливать структурные границы в условиях ограниченного объема и зашумленности исходных данных.

Заключение

Диссертационное исследование посвящено разработке и применению современных методов на основе нейронных сетей для решения актуальных задач интерпретации аномалий гравитационных и магнитных полей. В ходе работы разработаны инновационные методы, позволяющие автоматизировать процессы анализа геофизических данных, повысить точность интерпретации и значительно сократить временные затраты.

В работе предложен новый подход к выделению линейных и изометричных аномалий потенциальных полей на основе сверточных нейронных сетей архитектуры U-Net с предобученным энкодером на основе VGG-16. Выполнена его апробация как на модельных примерах, так и на реальных полях. При этом, особое внимание уделено созданию репрезентативных синтетических обучающих выборок, необходимых для нейронных сетей и компенсирующих наличие размеченных реальных данных.

Предложенный подход позволил решить задачу локализации масконов Луны в аномальном гравитационном поле с использованием сверточных нейронных сетей, показавшая преимущества перед классическими алгоритмами обработки изображений, особенно при работе с малоамплитудными аномалиями (до 200 мГал). Сверточные нейронные сети предоставили возможность не только идентифицировать известные по литературным данным масконы, но и выявлять новые. На примере комплексной интерпретации аномалий магнитного поля Баренцева моря апробирована методика применения обученных нейронных сетей для выделения изометричных и линейных аномалий, показавшая, что комбинация сетей позволяет получить согласованную схему геологического строения. Важно отметить, что применение нейронных сетей имеет временное преимущество при обработке больших массивов данных.

Основным научным результатом является разработка подходов к восстановлению структурных границ разреза с помощью нейронных сетей. Использование комплекса геофизических данных, включающего гравитационные и магнитные поля, показало, что нейронные сети, обученные на априорной информации на эталонных участках, решают задачу более устойчиво по сравнению с другими методами машинного обучения, особенно в условиях экстраполяции.

Все разработанные методы реализованы в виде программ на языке Python с использованием современных библиотек глубокого обучения, а практическая значимость работы подтверждена апробацией методов на реальных геофизических данных, включая материалы исследований Баренцева моря и гравитационного поля Луны.

В качестве рекомендаций по практическому применению результатов предлагается использование разработанных методов восстановления структурных горизонтов для построения

геологических разрезов на ранних этапах геолого-геофизических исследований, особенно в условиях ограниченного количества сейсмических данных и скважин; внедрение методики выделения аномалий на основе СНС в технологические схемы интерпретации гравитационных и магнитных полей; применение подхода создания синтетических обучающих выборок для других задач геофизики, где отсутствуют размеченные данные.

Перспективы дальнейших исследований видятся в расширении класса решаемых задач за счет применения более сложных архитектур нейронных сетей (трансформеры, генеративно-состязательные сети); разработке новых методов совместной интерпретации разнородных геофизических данных на основе нейросетевых технологий; применении предложенных подходов для изучения гравитационных и магнитных полей других планет и спутников Солнечной системы.

Полученные результаты открывают новые возможности автоматизации процессов интерпретации и могут быть использованы в различных областях геофизики – от поиска полезных ископаемых до изучения глубинного строения Земли и иных космических тел.

Благодарности

Автор выражает искреннюю благодарность своему научному руководителю и наставнику кандидату технических наук Кириллу Михайловичу Кузнецову за всестороннюю поддержку и помощь в выполнении работы на протяжении многих лет.

Автор искренне признателен сотрудникам кафедры геофизических методов исследования земной коры, особенно доктору геолого-минералогических наук Ивану Владимировичу Лыгину, доктору физико-математических наук Андрею Александровичу Булычеву, кандидату геолого-минералогических наук Татьяне Борисовне Соколовой, кандидату технических наук Льву Станиславовичу Чепиго, кандидату геолого-минералогических наук Давиду Артуровичу Арутюняну за всестороннюю помощь в реализации научных идей.

Автор выражает особую благодарность своей жене Софье Романовне Ивановой, всей большой семье и друзьям за мотивацию и веру в себя.

Список терминов

Алгоритм: точное предписание, определяющее вычислительный процесс, ведущий от варьируемых начальных данных к искомому результату. Это конечный упорядоченный набор четко определенных правил для решения проблемы.

Апсемплинг: операция увеличения размера карты признаков в нейронной сети.

Артефакты (в машинном обучении): нежелательные искажения или паттерны в выходных данных модели, не имеющие физического смысла и являющиеся следствием ошибок в алгоритме, данных или процессе обучения.

Архитектура нейронной сети: описание нейронной сети, в котором приведено, из каких слоев состоит нейронная сеть, каковы параметры этих слоев, описан процесс передачи данных между этими слоями, а также входом и выходом нейронной сети, но не указаны конкретные значения весов нейронной сети.

Аугментация данных: метод увеличения размера обучающей выборки путем создания модифицированных копий существующих данных (например, вращение, добавление шума и др.).

Бинарная маска: матрица, в которой каждый пиксель может принимать только одно из двух значений (обычно 0 или 1), используемое для обозначения принадлежности к определенному классу (например, объект/фон).

Валидационные данные: подмножество выборок входных данных, используемых для оценки прогноза результатов применения модели машинного обучения.

Верификация: процесс проверки того, что реализация модели машинного обучения (ее архитектура, алгоритмы обучения и предобработки данных) точно соответствует заданным проектным спецификациям и математическим формулам.

Гауссова регрессия: вид регрессии, при котором гауссовский процесс используется для нахождения распределения возможных значений для каждого входного данных, что позволяет оценить неопределенность прогноза.

Гиперпараметр: параметр алгоритма машинного обучения, влияющий на процесс обучения.

Глубокое обучение: подход к созданию обширных иерархических представлений посредством обучения нейронных сетей с большим количеством скрытых слоев.

Градиент: вектор, который показывает, как нужно изменить веса нейронной сети, чтобы уменьшить ошибку прогнозирования.

Градиентный бустинг: ансамблевый метод, в котором базовые алгоритмы обучаются последовательно для минимизации остаточных ошибок предыдущих алгоритмов с использованием градиентного спуска

Декодер: часть нейронной сети, которая преобразует сжатое представление данных обратно в подробное.

Дропаут: метод борьбы с переобучением, при котором во время обучения случайным образом отключается часть нейронов.

Затухающий градиент: проблема обучения глубоких сетей, при которой градиенты, распространяемые к начальным слоям, экспоненциально уменьшаются, препятствуя их эффективному обучению.

Карты признаков: промежуточные массивы данных, получаемы в результате применения слоев сверточной нейронной сети.

Клеточная нейронная сеть: специальный класс рекуррентных нейронных сетей, в которой нейроны (ячейки) расположены в регулярной решетке (часто двумерной) и соединены только с соседними ячейками в пределах своего локального окружения.

Конкатенация: операция объединения двух или более массивов данных (например, карт признаков) вдоль определенной оси.

Коэффициент регрессии: параметр в линейной регрессии, показывающий, насколько изменяется зависимая переменная при изменении независимой переменной на одну единицу.

Линейная регрессия: процесс нахождения линейной модели, минимизирующей функцию потерь между целевыми и прогнозируемыми значениями.

Машинное обучение: процесс, при котором система искусственного интеллекта использует вычислительные методы для автоматического обучения и улучшения на основе опыта или данных.

Метод опорных векторов: алгоритм машинного обучения, ключевая особенность которого заключается в минимизации обобщенной ошибки с использованием ϵ -нечувствительной функции потерь.

Метрика качества: числовой показатель, по которому оценивают качество работы обученной модели.

Многомерная регрессия: регрессия, в которой целевая переменная является многомерной, то есть предсказывает несколько числовых значений для каждого входного данных.

Многослойный перцептрон: тип искусственной нейронной сети прямого распространения, состоящий из множества слоев, в которой каждый нейрон соединен со всеми нейронами предыдущего и последующего слоев.

Модель машинного обучения: Модель, полученная в результате применения алгоритма машинного обучения к данным и используемая для получения выводов на основе новых данных.

Невязка: разность между наблюдаемыми (реальными) данными и данными, рассчитанными на основе полученной в процессе интерпретации модели.

Нейрон: базовый элемент нейронной сети, получающий одно или несколько входных значений и вырабатывающий выходное значение посредством комбинирования входных значений и применения функции активации к нему.

Нейронная сеть: сеть примитивных обрабатывающих элементов, соединенных взвешенными связями с регулируемым весами, в которой каждый элемент выдает значение, применяя нелинейную функцию к своим входным значениям, и передает его другим элементам или представляет его в качестве выходного значения.

Нелинейная регрессия: регрессия, в которой зависимость между переменными моделируется нелинейной функцией.

Нормировка данных: процесс приведения данных к единому масштабу, часто в диапазон $[0, 1]$ или с нулевым средним и единичной дисперсией.

Обратное распространение ошибки: метод обучения нейронной сети, при котором ошибка распространяется обратно по сети для обновления весов с целью минимизации ошибки.

Обучение: процесс создания или улучшения определенной функциональности алгоритмов искусственного интеллекта либо путем использования набора данных в качестве примеров для предполагаемого отношения вопрос/ответ, либо путем обеспечения положительной или отрицательной обратной связи с выходными данными, полученными для соответствующих входных данных.

Обучение без учителя: поиск скрытых закономерностей в данных без готовых ответов.

Обучение на синтетических данных: процесс обучения модели машинного обучения на данных, которые были сгенерированы искусственно с помощью математических моделей, а не собраны в реальном мире.

Обучение с учителем: обучение модели на данных с готовыми правильными ответами.

Оптимизатор: алгоритм, который обновляет параметры модели машинного обучения с целью минимизации функции потерь.

Параметризация: процесс представления сложного объекта или модели с помощью конечного набора параметров.

Перенос обучения: методика в машинном обучении, при которой модель, предварительно обученная на большой задаче (например, классификация изображений ImageNet), повторно используется или служит отправной точкой для решения другой, но схожей задачи с последующим дообучением модели.

Переобучение: ситуация, когда модель машинного обучения слишком хорошо подстраивается под обучающие данные, включая их шум и случайные флуктуации, и плохо работает на новых данных.

Перенос весов: соединения в нейронной сети, которые передают информацию из более ранних слоев (например, из энкодера) непосредственно на более поздние слои (например, в декодер). Это помогает избежать проблемы исчезающего градиента и позволяет сети сохранять мелкие детали.

Радиально-базисная нейронная сеть: нейронная сеть, в которой скрытые нейроны используют радиально-базисные функции в качестве функций активации, а выходной слой представляет собой линейную комбинацию выходов скрытых нейронов.

Размер пакета: параметр, устанавливающий для процесса обучения количество комплектов входных массивов нейронной сети, обрабатываемых нейронной сетью в одной итерации обучения, либо устанавливающий для применения нейронной сети количество одновременно обрабатываемых комплектов входных данных.

Регрессия с регуляризацией по Тихонову: модификация линейной регрессии, в которую добавлен штраф (L_2 -регуляризация) за большие значения коэффициентов для снижения переобучения.

Регуляризация (в машинном обучении): техника добавления дополнительного штрафа к функции потерь с целью предотвращения переобучения модели и повышения устойчивости решения обратной задачи.

Рекуррентная нейронная сеть: нейронная сеть, в которой как выходные данные предыдущего слоя, так и результаты предыдущего шага вычислений подаются на вход текущему слою.

Сверточная нейронная сеть: нейронная сеть прямого распространения, использующая свертку по крайней мере в одном из своих слоев.

Сверточный слой: слой нейронной сети, в котором входные данные обрабатываются с помощью свертки.

Сегментация (в контексте машинного обучения): задача массива данных на однородные по какому-либо признаку области (сегменты).

Синтетические данные: искусственно сгенерированные данные, которые имитируют свойства реальных данных и используются для обучения или тестирования моделей.

Скрытый слой: слой нейронов в нейронной сети, расположенный между входным и выходным слоями, предназначенный для выявления абстрактных признаков в данных.

Слой нейронной сети: фрагмент нейронной сети, который можно выделить в отдельную типовую параметризованную процедуру.

Слой объединения: слой в сверточной нейронной сети, который уменьшает размерность карт признаков, обобщая информацию с небольших участков.

Слой расширения: слой в нейронной сети, который увеличивает размерность данных, часто используемый в декодере для восстановления исходной матрицы данных.

Случайный лес: ансамблевый метод машинного обучения, который строит множество решающих деревьев и объединяет их результаты для повышения точности и устойчивости прогноза.

Смещение: дополнительный свободный член в нейронной сети, который позволяет сдвигать выходной результат независимо от входных данных.

Стридинг: шаг перемещения фильтра свертки по изображению.

Сходимость (алгоритма): свойство алгоритма достигать стабильного решения за конечное число итераций.

Тестовые данные: данные, которые удерживаются от процесса обучения и используются для оценки того, насколько хорошо модель машинного обучения будет работать с ранее не встречавшимися данными.

Функция активации: функция, которая определяет выходные данные нейрона на основе его входных данных или взвешенной суммы и вводит нелинейность в нейронную сеть.

Функция потерь: функция, которая определяет расхождение между прогнозируемыми значениями модели машинного обучения и фактическими значениями.

Экстремальный градиентный бустинг: алгоритм машинного обучения, который последовательно объединяет множество простых моделей (обычно деревьев решений), где каждая следующая модель исправляет ошибки предыдущих.

Энкодер: часть нейронной сети, которая сжимает входные данные, выделяя, с помощью слоев свертки, из них самые главные и полезные признаки.

Эпоха: один полный цикл обучения нейронной сети, когда алгоритм обработал все матрицы из обучающей выборки ровно по одному разу.

Список литературы

1. Бахвалов Н.С., Жидков Н.П., Кобельков Г.М. Численные методы 6-е изд. // М.: БИНОМ. Лаборатория знаний. 2008. 636 с.
2. Булычев А.А., Лыгин И.В., Соколова Т.Б., Кузнецов К.М. Прямая задача гравиразведки и магниторазведки (конспект лекций) // Учебное пособие – университетская книга, Москва. 2019. 176 с.
3. Бурнаев Е.В., Ерофеев П.Д., Приходько П.В. Выделение главных направлений в задаче аппроксимации на основе гауссовских процессов // Труды МФТИ. 2013. Том 5. № 3. С. 24-35.
4. Горбачевская Е.Н., Краснов С.С. История развития нейронных сетей // Вестник Волжского университета имени В.Н. Татищева. 2015. № 1 (23).
5. Горбаченко В.И., Артюхина Е.В. Два подхода к обучению радиально-базисных нейронных сетей при решении дифференциальных уравнений в частных производных // Технические науки. Информатика и вычислительная техника. 2007. № 2. С. 56-66.
6. Гравиразведка. Справочник геофизика // Под редакцией Е.А. Мудрецов, К.Е. Веселова. М.: Недра. 1990. 607 с.
7. Егоров Д.В., Кубышта И.И. Опыт применения сверточных нейронных сетей в задаче выделения разрывных нарушений по сейсмическим данным на примере шельфового месторождения Охотского моря // Геофизика. 2020. № 3. С. 38-44.
8. Колмаков А.В. Методы машинного обучения в задачах комплексной интерпретации данных потенциальных полей и сейсморазведки // ГеоЕвразия-2021 Геологоразведка в современных реалиях. 2021. Том II. С. 76-80.
9. Колмаков А.В. Построение структурной модели геологической среды на основе данных современной аэрогеофизической съемки и сейсморазведки МОГТ-2D // PRONEFTЬ. Профессионально о нефти. 2023. Том 8. № 4. С. 148-159.
10. Колмаков А.В., Трусков А.А., Мейснер А.Л., Григорьев Г.С. Моделирование морфологии отражающих горизонтов в межпрофильном пространстве по данным потенциальных полей методами глубокого обучения // ГеоЕвразия-2020. Современные технологии изучения и освоения недр Евразии. 2020. Том III. С. 76-80.
11. Леоненко А.Р., Даниловский К.Н., Петров А.М. Применение сверточных нейронных сетей для обработки и неитерационной экспресс-инверсии данных электрокаротажа при исследовании сложнопостроенных проницаемых отложений // ИНТЕРЭКСПО ГЕО-СИБИРЬ. 2021. Том 2. № 2. С. 123-129.

12. Лисенков И.А., Соловьев А.А., Кузнецов В.А., Николова Ю.И. Обобщенный массив геолого-геофизической информации восточного сектора Российской Арктики для проведения анализа методами машинного обучения // Геология и геофизика. 2025. Том 66. № 2. С. 232-246. DOI: 10.15372/GiG2024148.
13. Логинов Г.Н., Дучков А.А., Литвиченко Д.А., Алямкин С.А. Пример применения сверточных нейронных сетей в обработке реальных данных 3D сейсморазведки // Недропользование. Горное дело. Направление и технологии поиска, разведки и разработки месторождений полезных ископаемых. Экономика. Геоэкология. 2019. Том № 2. Выпуск № 3. С. 147-153.
14. Лыгин И.В., Арутюнян Д.А., Соколова Т.Б., Кузнецов К.М., Кривошея К.В. Картирование магматических комплексов по данным гидромагнитных съемок Баренцевоморского региона // Физика Земли. 2023. № 4. С. 96-114. DOI: 10.31857/S0002333723040075.
15. Магниторазведка. Справочник геофизика // Под редакцией В.Е. Никитского, Ю.С. Глебовского. М.: Недра. 1990. 490 с.
16. Никитин А.А., Петров А.В. Теоретические основы обработки геофизической информации. Учебное пособие // Москва, Издательство. 2008. 112 с.
17. Никитин А.А., Хмелевской В.К. Комплексирование геофизических методов. Учебник для вузов // Тверь: Издательство ГЕРС. 2004. 294 с.
18. Оборнев Е.А. Инверсия двумерных магнитотеллурических данных на основе нейросетевой аппроксимации // дис. ... канд. физ.-мат. наук: 25.00.10 / Оборнев Евгений Александрович – М. 2007. 143 с.
19. Петров А.В., Трусов А.А. Компьютерная технология статистического и спектрально-корреляционного анализа трехмерной геоинформации – КОСКАД 3D // Геофизика. 2000. № 4. С. 29-33.
20. Приезжев И.И., Иванов П.Д., Гаврилов С.С., Мамаев Д.А., Калинин А.Ю., Степин Ю.В. Автоматическая пикировка первых вступлений с использованием машинного обучения // Геофизика. 2022. № 1. С. 90-96.
21. Сагитов М.У. Лунная гравиметрия // М.: Наука. 1979. 432 с.
22. Ситникова Е.А. Анализ гравитационных эффектов моделей астроблем // Двадцать шестая уральская молодежная научная школа по геофизике: Сборник науч. материалов ГИ УрО РАН, Пермь. 2025. С. 145-149.
23. Созыкин А.В. Обзор методов обучения глубоких нейронных сетей // Вестник ЮУрГУ. Серия: Вычислительная математика и информатика. 2017. Том 6. № 3. С. 28-59.

24. Соколова Т.Б., Лыгин И.В., Кузнецов К.М., Булычев А.А., Коснырева М.В., Гилад Д.А., Тевелев А.В. Комплексные геофизические исследования: сейсморазведочные работы 3Д МОГТ в объеме 2800 полнократных квадратных километров, гравиметрическая и магнитометрическая съемки на Западно-Приновоземельском лицензионном участке (обработка и интерпретация грави магнитных данных). Лицензия ШБМ 15489 НР. Договор 011-15-ЗП // ФГБОУ ВО «Московский государственный университет имени М.В. Ломоносова». Москва. 2015ф. - 288 л., 112 р., 39/39 гр., 1 кн., 1 п., 1 м.н.
25. Спичак В.В. Электромагнитная томография земных недр // М.: Научный мир. 2019. 376 с.
26. Спичак В.В., Захарова О.К. Нейросетевое моделирование электромагнитного прогноза свойств геотермального резервуара // Физика Земли. 2023. № 1. С. 67-80.
27. Спичак В.В., Попова И.В. Применение нейросетевого подхода для реконструкции параметров трехмерной геоэлектрической структуры // Изв. РАН. Сер. Физика Земли. 1998. № 1. С. 39-45.
28. Хайкин С. Нейронные сети: полный курс, 2-е издание.: Пер. с англ. // М.: Издательский дом «Вильямс». 2006. 1104 с.
29. Чепиго Л.С. GravInv3D Программное обеспечение для трехмерного плотностного моделирования // Свидетельство о государственной регистрации программы для ЭВМ № 2020615095 от 14.05.2020 г. 2020.
30. Шимелевич М.И. Решение обратных задач геоэлектрики с применением нейронных сетей и оценкой неоднозначности // дис. ... док. физ-мат. наук: 1.6.9. / Шимелевич Михаил Ильич – М. 2024. 445 с.
31. Шклярук А.Д. Выделение структурных особенностей потенциальных полей на основе нейронных сетей // Выпускная квалификационная бакалаврская работа. 2020. 55 с.
32. Шклярук А.Д. Трансформации потенциальных полей на основе нейронных сетей // Выпускная квалификационная магистерская работа. 2022. 74 с.
33. Шклярук А.Д., Кузнецов К.М. Применение машинного обучения для построения структурных границ разреза по потенциальным полям // Гелиогеофизические исследования. 2023. № 38. С. 18-29. EDN: QKYSJY (0.75 п.л., авторский вклад 50%). Импакт-фактор 0.370 (РИНЦ).
34. Шклярук А.Д., Кузнецов К.М. Применение свёрточных нейронных сетей для выделения осей линейных аномалий магнитного поля // Russian Journal of Earth Sciences. 2025a. Том 25. № 4. С. ES4007. EDN: OZAKIC (0.75 п.л., авторский вклад 50%). Импакт-фактор 0.860 (РИНЦ).

35. **Шклярук А.Д.**, Кузнецов К.М. Программа для восстановления морфологии структурных поверхностей по геолого-геофизическим данным с помощью машинного обучения. // Свидетельство о государственной регистрации программы для ЭВМ № 2024614603 от 28.11.2024 г. 2024а.
36. **Шклярук А.Д.**, Кузнецов К.М. Программа для выделения изометричных аномалий магнитных и гравитационных полей на основе сверточных нейронных сетей. // Свидетельство о государственной регистрации программы для ЭВМ № 2024687213 от 17.03.2025 г. 2025б.
37. **Шклярук А.Д.**, Кузнецов К.М. Программа для выделения осей линейных аномалий магнитных и гравитационных полей на основе сверточных нейронных сетей. // Свидетельство о государственной регистрации программы для ЭВМ № 2024685140 от 14.10.2024 г. 2024б.
38. **Шклярук А.Д.**, Кузнецов К.М., Янголенко М.В., Беляков Н.В., Лыгин И.В. Выделение масконов Луны в гравитационном поле на основе свёрточных нейронных сетей // Геофизика. 2025. № 3. С. 97-105. EDN: HDKSGH. (0.56 п.л., авторский вклад 50%). Импакт-фактор 0.342 (РИНЦ).
39. Alom Z., Hasan M., Yakopcic C., Taha T.M., Asari V.K. Recurrent residual convolutional neural network based on U-Net (R2U-Net) for medical image segmentation. 2018.
40. Aydogan D. Extraction of lineaments from gravity anomaly maps using the gradient calculation: Application to Central Anatolia // Earth Planets Space. 2011. № 63. P. 903-913.
41. Aydogan D. Processing the Bouguer anomaly map of Biga and the surrounding area by the Cellular Neural Network: Application to the southwestern Marmara region // Earth Planets Space. 2007. № 59. P. 201-208.
42. Aydogan D., Elmas A., Albora A.M. A new approach to the structural features of the Aegean Sea: Cellular neural network // Mar.Geophys. Res. 2005. № 26. P. 1-15.
43. Bai Z., Wang Y., Wang C., Yu C., Lukyanenko D., Stepanova I., Yagola A.G. Joint Gravity and Magnetic Inversion Using CNNs' Deep Learning // Remote Sens. 2024. Vol. 16. P. 1-17.
44. Bergen K.J., Johnson P.A., De Hoop M.V. & Beroza G.S. Machine learning for data-driven discovery in solid Earth // Science. 2019. Vol. 363. Is. 6433. DOI:10.1126/science.aau0323.
45. Bezvesilna O., Tkachuk A., Chepyuk L., Nechai L., Khylichenko T. Introducing the principle of constructing an aviation gravimetric system with any type of gravimeter // Eastern-European Journal of Enterprise Technologies. 2017. № 85. P. 45-56.
46. Bishop C.M. Pattern Recognition and Machine Learning // Springer. 2006.
47. Bongioiolo A., Souza J., Francisco F., Castro L. Grav_mag_prism: A MATLAB®/octave program to generate gravity and magnetic anomalies due to rectangular prismatic bodies // Revista Brasileira de Geofisica. 2013. № 3(31). P. 347-363. DOI: 10.22564/rbgf.v31i3.310.

48. Bottou L. Large-scale machine learning with stochastic gradient descent // Proceedings of COMPSTAT'2010. 2010. P. 177-186.
49. Bradley D., Roth G. Adaptive thresholding using the integral image // Journal of Graphics GPU and Game Tools. 2007. Vol. 12. № 2. P.13-21.
50. Bradski G., Kaehler A. Learning OpenCV: Computer Vision with the OpenCV Library // O'Reilly Media. 2008. 580 p.
51. Breiman L. Random Forests // Machine Learning. 2001. Vol. 45. № 1. P. 5-32.
52. Canny J.A computational approach to edge detection // IEEE Transactions on Pattern Analysis and Machine Intelligence. 1986. Vol. PAMI-8. Is. 6. P. 679-698.
53. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2016.
54. Cho K., Van Merriënboer B., Gulcehre C., Bahdanau D., Bougares F., Schwenk H., Bengio Y. Learning phrase representations using RNN encoder-decoder for statistical machine translation // arXiv preprint arXiv:1406.1078. 2014.
55. Chollet F. Deep Learning with Python // Manning Publications. 2017. 384 p.
56. Cover T., Hart P. Nearest Neighbor Pattern Classification // IEEE Transactions on Information Theory. 1967. Vol. 13. № 1. P. 21-27.
57. Cybenko G. Approximation by superpositions of a sigmoidal function // Mathematics of Control, Signals and Systems. 1989. Vol. 2. P. 303-314.
58. Davis J., Goadrich M. The Relationship Between Precision-Recall and ROC Curves // Proceedings of the 23rd International Conference on Machine Learning (ICML '06). 2006.
59. Deng J., Dong W., Socher R., Li L.-J., Li K. & Fei-Fei L. ImageNet: A Large-Scale Hierarchical Image Database // IEEE Computer Vision and Pattern Recognition (CVPR). 2009. DOI: 10.1109/CVPR.2009.5206848.
60. Elawadi E., Salem A., Ushijima K. Detection of cavities and tunnels from gravity data using a neural network // Exploration Geophysics. 2001. № 32. P. 204-208.
61. El-kaliouby H.M., Al-Garni M.A. Inversion of self-potential anomalies caused by 2D inclined sheets using neural networks // Journal of Geophysics and Engineering. 2009. Vol. 6. № 1. P. 29-34.
62. Fassett C.I., Head J.W., Kadish S.J., Mazarico E., Neumann G.A., Smith D.E. & Zuber M.T. Lunar impact basins: Stratigraphy, sequence and ages from superposed impact crater populations measured from Lunar Orbiter Laser Altimeter (LOLA) data // Journal of Geophysical Research. 2012. Vol. 117. Is. E12. P. 1-13. DOI:10.1029/2011JE003951.
63. Friedman J.H. Greedy Function Approximation: A Gradient Boosting Machine // Annals of Statistics. 2001. Vol. 29. № 5. P. 1189-1232.

64. Geron A. Hands-On Machine Learning with Scikit-Learn, Keras and TensorFlow // O'Reilly Media, Inc. 2019. 856 p.
65. Glorot X., Bordes A., Bengio Y. Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics // PMLR 15. 2011. P. 315-323.
66. Goodfellow I., Bengio Y., Courville A. Deep Learning // MIT Press. 2016. 800 p.
67. Goodfellow I., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Bengio Y. Generative adversarial nets // Advances in neural information processing systems. 2014. 27.
68. Goossens S., Lemoine F.G., Sabaka T.J. Nicholas J.B., Mazarico E., Rowlands D.D., Loomis B.D., Chinn D.S., Neumann G.A., Smith D.E., Zuber M.T. A Global Degree and Order 1200 Model of the Lunar Gravity Field using GRAIL Mission Data // 47th Lunar and Planetary Science Conference, Houston, TX, Abstract №1484. 2016.
69. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction // Springer. 2009.
70. He K., Zhang X., Ren S., Sun J. Identity Mappings in Deep Residual Networks // Microsoft Research. 2016. DOI: 10.48550/arXiv.1603.05027.
71. Head J.W., Wilson L. Lunar mare volcanism: Stratigraphy, eruption conditions, and the evolution of secondary crusts // Geochimica et Cosmochimica Acta. 1992. Vol. 56. Is. 6. P. 2155-2175.
72. Hesham M., Mansour A. Inversion of self-potential anomalies caused by 2D inclined sheets using neural networks // J. Geophys. Eng. 2009. № 6. P. 29-34.
73. Hinton G.E., Osindero S., Teh Y.W. A fast learning algorithm for deep belief nets // Neural computation. 2006. Vol. 18. № 7. P. 1527-1554.
74. Hochreiter S., Schmidhuber J. Long short-term memory // Neural computation. 1997. Vol. 9. № 8. P. 1735-1780.
75. Hoerl A.E., Kennard R.W. Ridge Regression: Biased Estimation for Nonorthogonal Problems // Technometrics. 1970. Vol. 12. № 1. P. 55-67.
76. Huang H., Lin L., Tong R., Hu H., Zhang Q., Iwamoto Y., Han X., Chen Y.-W., Wu J. Huang H., Lin L., Tong R. UNet 3+: a full-scale connected UNet for medical image segmentation // IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2020. P. 1055-1059.
77. Jiao J., Zeng X., Liu H., Yu P., Lin T., Zhou S. Three-Dimension Inversion of Magnetic Data Based on Multi-Constraint UNet++ // Applied Sciences. 2024. Vol. 14. P. 1-23.
78. Kaftan I., Salk M., Senol Y. Evaluation of gravity data by using artificial neural networks case study: Seferihisar geothermal area (Western Turkey) // Journal of Applied Geophysics. 2011. № 75. P. 711-718.
79. Kingma D.P., Ba J. Adam: A Method for Stochastic Optimization // International Conference on Learning Representations (ICLR). 2015. DOI: 10.48550/arXiv.1412.6980.

80. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks // *Advances in neural information processing systems* 25. 2012.
81. LeCun Y., Bengio Y., Hinton G. Deep learning // *Nature*. 2015. № 521. P. 436-444. DOI: 10.1038/nature14539.
82. Liang Q., Chen C., Li Y. 3-D inversion of gravity data in spherical coordinates with application to the GRAIL data // *Journal of Geophysical Research Planets*. 2014. Vol. 119. P. 1359-1373. DOI: 10.1002/2014JE004626.
83. Lindeberg T. Feature detection with automatic scale selection // *Int. J. of Computer Vision*. 1998. Vol. 30. № 2. P. 1-51.
84. Lisenkov I.A, Soloviev A.A., Kuznetsov V.A., Nikolova Y.I. Generalized Dataset of Geological and Geophysical Information of the Eastern Sector of the Russian Arctic, VER. 1.0. 2023 // ESDB repository, GCRAS, Moscow. 2024. DOI: 10.2205/public-artcic-geospatial-data.
85. McCulloch W., Pitts W. A logical calculus of the ideas immanent in nervous activity // *The Bulletin of Mathematical Biophysics*. 1943. № 5(4). P. 115-133.
86. Miller H.G., Singh V. Potential field tilt--a new concept for location of potential field sources // *Journal of Applied Geophysics*. 1994. Vol. 32. Is. 2-3. P. 213-217.
87. Mosser L., Naeini E. Calibration and uncertainty quantification of bayesian convolutional neural networks for geophysical applications // *Machine Learning*. 2021. P. 1-25.
88. Muller P.M., Sjogren W.L. Mascons: Lunar Mass Concentrations // *Science*. 1968. Vol. 161. P. 680-684. DOI:10.1126/science.161.3842.680.
89. Nair V., Hinton G.E. Rectified linear units improve restricted boltzmann machines // *Proceedings of the 27th International Conference on Machine Learning*. 2010. P. 807-814.
90. Naprstek T., Smith R.S. Convolutional neural networks applied to the interpretation of lineaments in aeromagnetic data // *Geophysics*. 2022. Vol. 87. № 1. P. 1-13.
91. Neumann G.A., Zuber M.T., Wieczorek M.A., Head J.W., Baker D.M.H., Solomon S.C., Smith D.E., Lemoine F.G., Mazarico E., Sabaka T.J., Goossens S.J., Melosh H.J., Phillips R.J., Asmar S.W., Konopliv A.S., Williams J.G., Sori M.M., Soderblom J.M., Miljković K., Andrews-Hanna J.C., Nimmo F., Kiefer W.S. Lunar impact basins revealed by Gravity Recovery and Interior Laboratory measurements // *Science Advances*. 2015. Vol. 1. Is. 9. P. 1-10. DOI: 10.1126/sciadv.1500852.
92. Oktay O., Schlemper J., Le Folgoc L., Lee M., Heinrich M., Misawa K., Mori K., McDonagh S., Hammerla N.Y., Kainz B., Glocker B., Rueckert D. Attention U-Net: learning where to look for the pancreas // *1st Conference on Medical Imaging with Deep Learning (MIDL 2018)*, Amsterdam, The Netherlands. 2018.

93. Osman O., Albore A.M., Ucan O.N. A new approach for residual gravity anomaly profile interpretations: Forced Neural Network (FNN) // *Annals of geophysics*. 2006. Vol. 49. № 6. P. 1201-1208.
94. Otsu N. A threshold selection method from gray-level histograms // *IEEE Transactions on Systems, Man, and Cybernetics*. 1979. Vol. 9. Is. 1. P. 62-66.
95. Pedregosa F., Varoquaux G., Gramfort A., Michel V., Thirion B., Grisel O., Blondel M., Müller A., Nothman J., Louppe G., Prettenhofer P., Weiss R., Dubourg V., Vanderplas J., Passos A., Cournapeau D., Brucher M., Perrot M., Duchesnay E. Scikit-learn: Machine Learning in Python // *Journal of Machine Learning Research*. 2011. P. 2825-2830. DOI: 10.48550/arXiv.1201.0490.
96. Peters B., Haber E., Granek J. Neural-networks for geophysicists and their application to seismic data interpretation // *arXiv: Learning*. 2019.
97. Plouff D. Gravity and Magnetic fields of polygonal prisms and application to magnetic terrain corrections // *Geophysics*. 1976. Vol. 41. № 4. P. 727-741. DOI: 10.1190/1.1440645.
98. Prechelt L. Early stopping-but when? // *Neural Networks: Tricks of the Trade*. 1998. P. 55-69.
99. Rahman M.A., Wang Y. Optimizing Intersection-Over-Union in Deep Neural Networks for Image Segmentation // *Advances in Visual Computing. ISVC*. 2016. P. 234-244.
100. Rohit, Manda S.R., Raj A., Dheeraj A., Rawat G.S., Choudhury T. Identification of Lithology from Well Log Data Using Machine Learning // *EAI Endorsed Trans IoT*. 2024. Vol. 10. P. 1-10.
101. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // *MICCAI 2015. Lecture Notes in Computer Science*. 2015. Vol. 9351. Springer, Cham. DOI: 10.1007/978-3-319-24574-4_28.
102. Rosenblatt F. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain // *Psychological Review*. 1958. Vol. 65 (6). P. 386-408.
103. Rumelhart D.E., Hinton G.E., Williams R.J. Learning representations by back-propagating errors // *Nature*. 1986. Vol. 323(6088). P. 533-536.
104. Silva R.M., Baroni L., Ferreira R.S., Civitarese D., Szwarcman D., Brazil E.V. Netherlands Dataset: A New Public Dataset for Machine Learning in Seismic Interpretation // *arXiv: Learning*. 2019.
105. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition // *ICLR*. 2015. DOI: 10.48550/arXiv.1409.1556.
106. Smola A.J., Schölkopf B. A Tutorial on Support Vector Regression // *Statistics and Computing*. 2004. Vol. 14. № 3. P. 199-222.
107. Soille P. *Morphological Image Analysis* // Springer Science & Business Media. 2013. 392 p.

- 108.Sokolova M., Lapalme G. A systematic analysis of performance measures for classification tasks // *Information Processing & Management*. 2009. Vol. 45. № 4. P. 427-437.
- 109.Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R. Dropout: A simple way to prevent neural networks from overfitting // *Journal of Machine Learning Research*. 2014. Vol. 15. № 1. P. 1929-1958.
- 110.Stankovic L., Mandic D. Convolutional Neural Networks Demystified: A Matched Filtering Perspective Based Tutorial. 2021. DOI: 10.48550/arXiv.2108.11663.
- 111.Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Rabinovich A. Going deeper with convolutions // *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2015a.
- 112.Szegedy C., Vanhoucke V., Ioffe S., Shlens J., Wojna Z. Rethinking the Inception Architecture for Computer Vision. 2015b. DOI: 10.48550/arXiv.1512.00567.
- 113.Tan M., Le Q.V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks // *ICML*. 2019. DOI: 10.48550/arXiv.1905.11946.
- 114.Tartèse R., Anand M., Gattacceca J. Joy K.H., Mortimer J.I., Pernet-Fisher J.F., Russell S., Snape J.F., Weiss B.P. Constraining the Evolutionary History of the Moon and the Inner Solar System: A Case for New Returned Lunar Samples // *Space Science Reviews*. 2019. Vol. 215. DOI: 10.1007/s11214-019-0622-x.
- 115.Tieleman T, Hinton G. Lecture 6.5-rmsprop: Divide the Gradient by a Running Average of Its Recent Magnitude // *COURSERA: Neural Networks for Machine Learning*. 2012. № 4. P. 26-31.
- 116.Turgut B. Application of back propagation artificial neural networks for gravity fields modelling // *Acta Montanistica Slovaca*. 2016. Vol. 21. № 3. P. 200-207.
- 117.Venkatesan R., Li B. Convolutional Neural Networks in Visual Computing // *CRC Press*. 2017. 186 p.
- 118.Wu X., Liang L., Shi Y., Fomel S. FaultSeg3D: Using synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation // *Geophysics*. 2019. 84(3). IM35-IM45.
- 119.Yang H., Xiong J., Cao Y. 2D Inversion of Magnetic Anomaly data based on Deep Learning // *International Journal of Science and Engineering Applications*. 2024. Vol. 13. Is. 1. P. 1-4. DOI:10.7753/IJSEA1301.1001.
- 120.Yang L, Sun S.Z. Seismic horizon tracking using a deep convolutional neural network // *Journal of Petroleum Science and Engineering*. 2020. Vol. 187. P. 1-15.
- 121.Zhang J., Shan X., Huo S., Huang L., Zheng W., Zhou X., Liu E. Deep learning-driven multi-frequency seismic inversion for enhanced thin-layer stratigraphic characterization // *Journal of Applied Geophysics*. 2025. Vol. 239. <https://doi.org/10.1016/j.jappgeo.2025.105749>.

- 122.Zhang L., Zhang G., Liu Y. and Fan Z. Deep Learning for 3-D Inversion of Gravity Data // IEEE Transactions on Geoscience and Remote Sensing. 2022. Vol. 60. P. 1-18.
- 123.Zhang T.Y., Suen C.Y. A fast parallel algorithm for thinning digital patterns // Communications of the ACM. 1984. Vol. 27. Is. 3. P. 236-239.
- 124.Zhang Z., Chen R., Ma J. Improving Seismic Fault Recognition with Self-Supervised Pre-Training: A Study of 3D Transformer-Based with Multi-Scale Decoding and Fusion // Remote Sens. 2024. Vol. 16. Is. 5. <https://doi.org/10.3390/rs16050922>.
- 125.Zhao G., Liu J., Chen B., Kaban M.K., Du J. 3-D Density Structure of the Lunar Mascon Basins Revealed by a High-Efficient Gravity Inversion of the GRAIL Data // Journal of Geophysical Research Planets. 2021. Vol. 126. Is. 5. P. 1-22. DOI: 10.1029/2021JE006841.
- 126.Zhou X., Chen Z., Chen H., Wang S., Kubeka Z.O. Edge Detection of Source Body from Magnetic Anomaly Based on ResNet // Remote Sensing. 2024. Vol. 16. P. 1-21.
- 127.Zhou Z., Siddiquee M.M.R., Tajbakhsh N., Liang J. Unet++: A nested U-Net architecture for medical image segmentation // Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. 2018. P. 3-11.