



**ОРМАН ИНДИРА МӘЛІКҚЫЗЫ**

**Разработка алгоритмов и программного обеспечения для определения электромагнитных параметров включения в подстилающей среде.**

8D06101 – Информатика, вычислительная техника и управление

Диссертация на соискание степени  
доктора философии (PhD)

Научные консультанты  
кандидат технических наук,  
ассоциированный профессор  
И.Г. Курмашев

доктор физика-математических наук,  
профессор,  
К.Т. Искаков

Зарубежный консультант  
доктор PhD,  
профессор  
Mosavi A.A.

## СОДЕРЖАНИЕ

<b>НОРМАТИВНЫЕ ССЫЛКИ</b> .....	3
<b>ОПРЕДЕЛЕНИЯ</b> .....	4
<b>ОБОЗНАЧЕНИЯ И СОКРАЩЕНИЯ</b> .....	7
<b>ВВЕДЕНИЕ</b> .....	9
<b>1 АНАЛИЗ АЛГОРИТМОВ И МОДЕЛЕЙ ОБРАБОТКИ ГЕОРАДИОЛОКАЦИОННЫХ ДАННЫХ</b> .....	21
1.1 Основы георадиолокации и принципы функционирования георадара «Лоза-В».....	22
1.2 Метод зондирования и алгоритмы первичной обработки георадиолокационных сигналов .....	28
1.3 Численные алгоритмы и методы машинного обучения для решения задач георадиолокации .....	29
1.4 Методика интерпретации реальных радарограмма.....	37
Выводы к первому разделу.....	40
<b>2 ИНТЕРПРЕТАЦИЯ ГЕОРАДИОЛОКАЦИОННЫХ ДАННЫХ</b> .....	43
2.1 Первичная обработка реальных данных георадара.....	44
2.2 Интерактивные способы определения геоэлектрического разреза.....	51
2.3 Определение зависимости электрической проницаемости от влажности.....	56
Выводы ко второму разделу.....	64
<b>3 МЕТОДИКА МОНИТОРИНГА И ДИАГНОСТИКИ СТРУКТУРНОГО СОСТОЯНИЯ ПОДПОВЕРХНОСТНЫХ СЛОЁВ НА ОСНОВЕ МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ</b> .....	66
3.1 Описание данных. Методы моделирования.....	67
3.2 Статистические характеристики набора данных. Результаты моделирования.....	70
Выводы к третьему разделу.....	78
<b>4 РАЗРАБОТКА МЕТОДА ОПРЕДЕЛЕНИЯ ПАРАМЕТРОВ ИСТОЧНИКА И ПОДСТИЛАЮЩЕГО СЛОЯ</b> .....	81
4.1 Математическое моделирование уточнения формы источника.....	81
4.2 Метод определения параметров источника на основе применения оптимизационного метода .....	85
4.3 Метод решения задачи по определению диэлектрической проницаемости и проводимости включений в подстилающей среде.....	88
Выводы к четвертому разделу.....	93
<b>ЗАКЛЮЧЕНИЕ</b> .....	94
<b>СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ</b> .....	98
<b>ПРИЛОЖЕНИЕ А – Свидетельство об авторском праве</b> .....	106
<b>ПРИЛОЖЕНИЕ Б – Акты внедрения</b> .....	107
<b>ПРИЛОЖЕНИЕ В – Результат обработки в программе «Крот»</b> .....	110
<b>ПРИЛОЖЕНИЕ Д – Обработка точечных данных и построение модели по этим данным в программе MATLAB</b> .....	115

## НОРМАТИВНЫЕ ССЫЛКИ

В настоящей диссертации использованы ссылки на следующие стандарты:  
ГОСТ 7.32–2017. Отчёт о научно-исследовательской работе. Структура и правила оформления.

ГОСТ 7.1-2003. Библиографическая запись. Библиографическое описание.

СТ РК ГОСТ 2.105-2003. Единая система конструкторской документации.

Общие требования к текстовым документам.

СТ РК ГОСТ 19.201-2005. Единая система программной документации.

Требования к содержанию и оформлению программ.

СТ РК ГОСТ 2.601-2013. ЕСКД. Эксплуатационные документы.

СТ РК ГОСТ 19.301-79. ЕСКД. Тестирование программ. Общие положения.

СТ РК ГОСТ 8.417-2002. ГСИ. Единицы физических величин.

СТ РК ГОСТ 7.05-2008. Библиографическая ссылка. Общие требования и правила составления.

ГОСТ Р 59120-2021. Дороги автомобильные общего пользования. Дорожная одежда. Общие требования.

## ОПРЕДЕЛЕНИЯ

В настоящей диссертации применяют следующие термины с соответствующими определениями:

**Калибровочная функция** – это функция, которая преобразует предсказанные вероятности модели в откалиброванные вероятности, чтобы они соответствовали реальной вероятности наступления события.

**«Лоза-В»** – среднечастотный импульсный георадар (ground-penetrating radar), работающий в диапазоне примерно 50–300 МГц, который регистрирует полную волновую форму отражённых электромагнитных сигналов при зондировании подповерхностных сред с целью выявления слоёв, аномалий и объектов под землёй или под другими поверхностями.

**Профилирование** – это метод исследования, при котором выполняются последовательные измерения физических характеристик среды вдоль заданной линии или трассы с целью построения пространственного профиля структуры подповерхностных слоёв, выявления аномалий и объектов.

**Зондирование** – это процесс получения информации о внутренней структуре, составе или свойствах среды путём регистрации откликов на воздействие измерительного сигнала (электрического, электромагнитного, акустического, механического и др.) с помощью зонда.

**Влагомер МГ-4** – электронный прибор для оперативного контроля и измерения влажности различных материалов (дерева, бетона, песка, грунта и др.) путём регистрации зависимости диэлектрической проницаемости исследуемого материала от его содержания влаги.

**Георадиолокационная система** – это комплексное техническое устройство, сочетающее в себе принципы работы радара и системы геолокации. Эта система использует радиоволновое излучение для обнаружения, отслеживания и определения местоположения объектов на поверхности Земли. Георадиолокационные системы применяются в различных областях, включая военное дело, гражданскую авиацию, метеорологию и геологические исследования, обеспечивая точный и эффективный мониторинг пространства и объектов на поверхности.

**Георадар (GPR)** – прибор неразрушающего контроля, использующий электромагнитные импульсы сверхвысокой частоты для исследования структуры и свойств подповерхностной среды.

**Георадиолокация** – метод исследования среды, основанный на излучении и регистрации отражённых электромагнитных волн от границ раздела сред с различными электрофизическими параметрами.

**Подстилающая среда** – среда, в которой распространяются электромагнитные волны и внутри которой расположены исследуемые включения (грунт, бетон, асфальтобетон и др.).

**Включение** – локальный объект или неоднородность в подстилающей среде, отличающаяся по своим электромагнитным параметрам от окружающего материала.

**Электромагнитные параметры среды** – совокупность физических характеристик, определяющих распространение электромагнитных волн в среде: диэлектрическая проницаемость, электрическая проводимость и магнитная проницаемость.

**Диэлектрическая проницаемость ( $\epsilon$ )** – физическая величина, характеризующая способность среды поляризоваться под действием электрического поля и влияющая на скорость распространения электромагнитной волны.

**Относительная диэлектрическая проницаемость ( $\epsilon_0$ )** – отношение диэлектрической проницаемости среды к диэлектрической проницаемости вакуума.

**Электрическая проводимость ( $\sigma$ )** – физическая величина, характеризующая способность среды проводить электрический ток.

**Коэффициент отражения ( $\alpha$ )** – величина, определяющая отношение амплитуды отражённой волны к амплитуде падающей волны на границе раздела двух сред.

**Инверсия георадарных данных** – процесс определения электромагнитных параметров среды на основе анализа зарегистрированных отражённых сигналов.

**Алгоритм обработки данных** – последовательность математических и вычислительных операций, направленных на фильтрацию, усиление полезного сигнала и интерпретацию результатов измерений.

**Программное обеспечение обработки георадарных данных** – комплекс программных средств, предназначенных для автоматизированной обработки, визуализации и интерпретации радарограмм.

**Геофизические методы** – это совокупность техник исследования Земли с использованием физических принципов и явлений, таких как сейсмическое, электромагнитные и гравитационные методы (Lowrie, 2007).

**Задача оптимизации** представляет собой поиск наилучшего решения для заданных условий и критериев, минимизируя или максимизируя целевую функцию (Boyd & Vandenberghe, 2004).

**Интерпретация** – это процесс объяснения или понимания значения данных, результатов исследования или концепций с целью их более полного и понятного представления.

**Каротаж** – это географический метод исследования скважин, основанный на измерении различных физических параметров пород, преодолеваемых буровым инструментом в процессе бурения (Rider, 1996).

**Научно-технический анализ** представляет собой метод исследования, направленный на анализ научных и технических данных с целью выявления закономерностей и трендов (Dess & Lumpkin, 2005).

**Надповерхностная электроразведка** – метод геофизического исследования, использующий электрические свойства грунта на поверхности Земли для анализа подземных структур (Nabighian, 1979).

**Обратная задача** – это научный подход, заключающийся в определении неизвестных параметров модели или процесса на основе известных результатов (Aster et al., 2005).

**Программное обеспечение** представляет собой совокупность программных продуктов, включая операционные системы и прикладные программы, предназначенных для управления аппаратными ресурсами компьютера и решения конкретных задач пользователя (Stallings, 2015).

**Программно-аппаратный комплекс** представляет собой систему, объединяющую программное обеспечение и аппаратные средства для решения сложных задач, обеспечивая взаимодействие и совместную работу между ними (Лихтарович, 2006).

**Прямая задача** в науке о моделировании означает вычисление результатов эксперимента или явления на основе известных входных данных и параметров модели (Ciarlet, 2013).

**Радарограмма** – это графическое изображение данных, полученных с помощью радара, позволяющее визуализировать объекты или структуры в зависимости от их электромагнитных характеристик (Ulaby et al., 2014).

**Электрические свойства** – это физические характеристики вещества, связанные с его проводимостью электрического тока и взаимодействием с электрическим полем (Gupta, 2017).

**Электромагнитные свойства** – это характеристики вещества, связанные с его взаимодействием с электромагнитным полем, включая проводимость, диэлектрическую проницаемость и магнитные свойства (Smythe, 1989).

**Интеграция радарограммы** – это метод обработки данных георадара, при котором измеренные амплитуды отражённых сигналов суммируются или усредняются вдоль трассы или во времени для получения количественной оценки отражающих объектов или материалов.

**Калибровка** – это процесс настройки или корректировки измерительного прибора, модели или системы для получения точных и правильных результатов.

## ОБОЗНАЧЕНИЯ И СОКРАЩЕНИЯ

AFMAG	– Audio-Frequency Magnetotellurics/метод магнитотеллурической разведки в аудиочастотном диапазоне
AVO	– Amplitude Versus Offset/анализ изменения амплитуды волны в зависимости от удаления источника
CDP	– Common Depth Point/метод многократного перекрытия в сейсморазведке
CSEM	– Controlled Source Electromagnetics/метод контролируемых источников электромагнитного излучения
CPU	– центральный процессор
FWI	– Full Waveform Inversion/полноволновая инверсия
GPR	– Ground Penetrating Radar/георадар
HDR	– High Dynamic Range/технология высокой динамической контрастности
IEEE	– международный институт инженеров электротехники и электроники
MATLAB	– программная среда для математического моделирования
ML	– Machine Learning/машинное обучение
NDE	– Non-Destructive Evaluation/неразрушающая оценка
PDE	– Partial Differential Equations/уравнения в частных производных
PRISMA	– методология систематических обзоров
RADEXPRO	– программное обеспечение для обработки геофизических данных
SEG	– Society of Exploration Geophysicists/общество разведочной геофизики
НДС	– напряженно-деформированное состояние
ОЗУ	– оперативная запоминающая память
КОКСНВО	– Комитет по обеспечению качества в сфере науки и высшего образования Министерства науки и высшего образования Республики Казахстан
МНВО РК	
CNN	– Convolutional Neural Network/ многослойная нейронная сеть, использующая сверточные слои для автоматического извлечения признаков из данных с пространственной структурой (например, изображений) и последующей классификации или регрессии
PSL	– Phase Shift Laser/лазерная система, работающая на принципе измерения фазового сдвига лазерного сигнала для точного определения расстояний или параметров объектов
DL	– Deep Learning/раздел машинного обучения, использующий глубокие многослойные нейронные сети для автоматического извлечения признаков и построения моделей на сложных данных

SHM	– Structural Health Monitoring/система или методика мониторинга состояния конструкций, обеспечивающая обнаружение повреждений и оценку долговечности инженерных сооружений в реальном времени
PMS	– Power Management System/система управления энергопотреблением, обеспечивающая контроль, оптимизацию и распределение энергии в электрических или электронных системах
GAN	– Generative Adversarial Network/тип нейронной сети, состоящий из генератора и дискриминатора, обучаемых в состязательном режиме для создания реалистичных искусственных данных, близких к реальным
IoT	– Internet of Things/концепция сети физических объектов, оборудованных датчиками, программным обеспечением и связью, которые собирают и обмениваются данными через интернет
SVM	– Support Vector Machine/алгоритм машинного обучения для классификации и регрессии, который ищет оптимальную гиперплоскость, разделяющую данные на классы с максимальным отступом
ANN	– Artificial Neural Network/математическая модель, имитирующая работу биологических нейронов, способная обрабатывать данные, распознавать закономерности и прогнозировать результаты
RFR	– Random Forest Regression/алгоритм ансамблевого машинного обучения, использующий множественные решающие деревья для предсказания числовых значений с целью уменьшения переобучения и повышения точности
GBM	– Gradient Boosting Machine/ метод ансамблевого обучения, с целью создания точной модели классификации или регрессии

## ВВЕДЕНИЕ

**Актуальность исследования.** В условиях интенсивного развития инфраструктуры и постоянного увеличения эксплуатационных нагрузок существенно возрастает роль методов диагностики и мониторинга технического состояния объектов. Их использование позволяет не только своевременно выявлять дефекты и повреждения, но и обеспечивает устойчивость функционирования конструкций, способствует продлению их срока службы, а также снижению затрат на ремонт и техническое обслуживание. В этой связи эффективные технологии контроля состояния инфраструктурных систем становятся одним из ключевых факторов их безопасной и экономически оправданной эксплуатации. На этом фоне особое значение приобретают методы неразрушающего контроля, позволяющие получать информацию о состоянии объектов без вмешательства в их структуру. Среди них выделяется георадиолокация (GPR), обеспечивающая получение достоверных данных о внутреннем строении исследуемых сред. Данный метод нашёл широкое применение в строительстве, инженерной геологии и диагностике подповерхностных слоёв дорожных конструкций. Его популярность обусловлена высокой информативностью, оперативностью проведения исследований и способностью выявлять скрытые дефекты, недоступные традиционным способам контроля. Вместе с тем практическая реализация данного метода связана с необходимостью корректной интерпретации получаемых данных, что определяет переход от общих возможностей технологии к особенностям её применения. Метод георадиолокации основан на излучении электромагнитных импульсов в исследуемую среду и регистрации отражённых сигналов с помощью встроенных антенн. Результаты измерений представляются в виде радарограммы - временной развертки отражённых сигналов.

В контексте реализации задач, озвученных Главой государства в Послании «Казахстан в эпоху искусственного интеллекта: цифровая трансформация» от 8 сентября 2025 года, данная работа приобретает особую значимость. Разработка авторского программного обеспечения для определения электромагнитных характеристик объектов в подстилающей среде выступает практическим воплощением курса на цифровую интеграцию и интеллектуализацию производства. Создаваемый в рамках исследования инструментарий позволяет автоматизировать интерпретацию данных дистанционного зондирования, что открывает новые возможности для повышения эффективности геологоразведочных и инженерно-технических работ в условиях цифровой экономики».

«Казахстан в эпоху искусственного интеллекта: цифровая трансформация» 8 сентября 2025 года [1].

Георадар способен излучать электромагнитные импульсы в среду обследования, а антенны встроенные в прибор принимать и записывать отраженные сигналы, затем строить радарограмму отраженных сигналов. Радарограмма является разверткой, зависящей от времени. Задача

интерпретации радарограммы состоит в переходе от временной развертки получить функцию от глубины, а именно геоэлектрический разрез: диэлектрическая проницаемость и проводимость неоднородных сред [2].

Задача интерпретации радарограмм является сложной и актуальной задачей, и зависит от программного обеспечения встроенной в георадар, а также от опыта геофизика читающих радарограммы. Как правило этот опыт связан с чтением радарограмм ряда экспериментов, проведенных на практике. Существуют другое направление интерпретации радарограмм, а именно использования математического компьютерного моделирования.

Радарограмма отражает временные характеристики распространения сигнала, в частности время пробега электромагнитной волны до границы неоднородности. Однако в практических задачах приоритетным является восстановление геофизических параметров среды по глубине [2]. В случае анализа отражённых электромагнитных волн к ключевым параметрам исследуемых объектов относятся диэлектрическая проницаемость и электрическая проводимость среды.

С математической точки зрения такого сорта задачи относятся к обратным и некорректным задач. Первые работы из этого направления следуют из работ академика А.Н. Тихонова [3]. Им введено новое понятие корректности в отличии от корректности решения задачи по Адамару. Корректность по Тихонову состоит из следующих позиций: 1. Решение задачи существует в некотором множестве (класс корректности) 2. Решение единственно в классе корректности. 3. Решение задачи устойчиво (малым изменениям начальным данным соответствуют малые изменения решения). В этой работе им впервые доказано единственность решения обратной задачи для уравнения электродинамики. Прямая задача состоит в следующем, предполагается, что все коэффициенты и правая часть рассматриваемого уравнения, а также известны краевые и начальные условия в некотором множестве, необходимо найти решение задачи в этом классе. Если относительно решения прямой задачи известна дополнительная информация, например поведение ее решения в некоторой точке наблюдения, то можно сформулировать постановку обратной задачи. Суть обратной задачи состоит в следующем: по известной дополнительной информации и известным краевым, начальным условия и правой части уравнения найти коэффициент, входящий в рассматриваемое уравнение и решение задачи, причем зависящий от этого коэффициента. С практической точки зрения такая постановка обратной коэффициентной задачи актуальна и востребована. С использованием прибора георадара, а именно данные получаемых антенной являются дополнительной информацией о котором было сказано выше. Таким образом этот подход нами будет использован в настоящей работе.

Для широкого круга прикладных и теоретических задач основы теории обратных и некорректных задач сформированы и продолжают развиваться в работах Лаврентьева М.М., и других [4], а также их научной школы и последователей. Фундаментальные теоретические аспекты, включая теоремы единственности и устойчивости решений в рамках корректно поставленных обратных задач математической физики, изложены в монографии Романова В.Г.

[5]. Вопросы построения численных методов решения обратных задач для уравнений геоэлектрики рассмотрены в работах Романова В.Г., Кабанихина С.И. [6]. Численные методы решения коэффициентных обратных задач с использованием оптимизационных подходов представлены в монографии Кабанихина С.И., Искакова К.Т. [7, 8].

**Целью диссертационного исследования** разработка алгоритмов и программного обеспечения для определения электромагнитных параметров (диэлектрической проницаемости и проводимости) включений в подстилающей среде по данным георадиолокационного зондирования, включая калибровку источника, оценку глубины залегания и применение методов глубокого обучения для мониторинга состояния подповерхностных слоёв.

Для осуществления поставленной цели были определены **следующие задачи:**

1. Проанализировать существующие алгоритмы и методы георадиолокации для определения электромагнитных параметров подстилающей среды.

2. Разработать и реализовать методы определения глубины залегания на основе экспериментальных исследований георадаром «Лоза-В» методом зондирования и определения диэлектрической проницаемости и проводимости на основе инженерно-технических подходов.

3. Разработать методические подходы первоначальной обработке реальных данных георадара и определить калибровочную функцию влияния коэффициента влажности сред на коэффициент диэлектрической проницаемости.

4. Разработать методику мониторинга и диагностики структурного состояния подповерхностных слоёв на основе методов глубокого обучения для интерпретации георадиолокационных данных.

5. Разработать метод определения параметров источника на основе применения оптимизационного метода.

6. Разработать метод решения задачи по определению диэлектрической проницаемости и проводимости включений в подстилающей среде на основе аналитического решения для уравнения геоэлектрики в частотной области.

**Объектом диссертационного исследования** являются процессы распространения и отражения электромагнитных волн в подповерхностных неоднородных средах при георадиолокационном зондировании.

**Предметом диссертационного исследования** являются алгоритмы и математические модели обработки и интерпретации георадиолокационных данных.

**Основные положения, выносимые на защиту:**

1. Разработаны и реализованы методы определения глубины залегания на основе экспериментальных исследований проведённых методом зондирования с использованием георадара «Лоза-В», а также методы определения диэлектрической проницаемости и проводимости на основе инженерно-технических подходов, что обеспечивает повышение точности интерпретации георадиолокационных данных.

2. Предложены методические подходы к интерпретации и первоначальной обработке реальных данных георадара для практического применения, а также к определению калибровочной функции влияния коэффициента влажности среды на коэффициент диэлектрической проницаемости.

3. Разработана методика мониторинга и диагностики структурного состояния подповерхностных слоёв на основе методов глубокого обучения для интерпретации георадиолокационных данных, что позволяет повысить точность распознавания неоднородностей и снизить зависимость результатов от субъективного опыта специалиста.

4. Разработан метод определения параметров источника на основе применения оптимизационного метода, что обеспечивает повышение достоверности интерпретации за счёт согласования модели с экспериментальными данными.

5. Разработан метод решения задачи по определению диэлектрической проницаемости и проводимости включений в подстилающей среде на основе аналитического решения уравнения геоэлектрики в частотной области, что позволяет повысить точность восстановления геофизических характеристик исследуемых объектов.

#### **Научная новизна исследования:**

1. Разработаны методы определения глубины залегания на основе экспериментальных исследований, проведенных методом зондирования с использованием георадара «Лоза-В» и методы определения диэлектрической проницаемости и проводимости на основе инженерно-технических подходов.

2. Предложены методические подходы к интерпретации и первоначальной обработке реальных данных георадара для практического применения.

3. Разработана методика мониторинга и диагностики структурного состояния подповерхностных слоёв на основе методов глубокого обучения для интерпретации георадиолокационных данных, что позволяет повысить точность распознавания неоднородностей и снизить зависимость результатов от субъективного опыта специалиста.

4. Разработан метод определения параметров источника на основе применения оптимизационного метода в табличной форме.

5. Разработан метод решения задачи по определению диэлектрической проницаемости и проводимости включений в подстилающей среде на основе аналитического решения уравнения геоэлектрики в частотной области без применения итерационных оптимизационных методов.

**Методологические основы и методы исследования:** Применение инженерно-технических методов на основе физически обоснованных формул; математическое моделирование определения функции источника в табличной форме; определение электромагнитных свойств включения в подстилающей среде на основе аналитического метода решения задачи геоэлектрики в частотной области, а также применения методов оптимизации. Использование

методов глубокого обучения (в том числе рекуррентные нейронные сети типа LSTM)

**Теоретическая значимость:** С применением неразрушающих методов, в частности георадара, исследуются подповерхностные структуры неоднородной среды, включающей асфальтобетон, щебень различных фракций, песок и суглинки. Антенна георадара фиксирует в каждой точке наблюдения время пробега отражённой электромагнитной волны от границ раздела сред с различными электрофизическими свойствами. Задача интерпретации радарограмм заключается в восстановлении глубинного (геоэлектрического) разреза по известной функции времени пробега сигнала. В ходе исследования использованы уравнения Максвелла, описывающие распространение электромагнитных волн в средах с различными параметрами. Также рассмотрена задача продолжения поля, которая с физической точки зрения обусловлена тем, что электромагнитные свойства исследуемого объекта могут существенно отличаться от свойств вмещающей среды. В результате неоднородные включения выступают в роли источников вторичных волн, что приводит к усложнению процесса интерпретации георадарных данных. При использовании алгоритмов определения геоэлектрических характеристик неоднородной среды на основе методов математического моделирования требуется табличное (дискретное) представление источника возбуждения электромагнитных волн, обеспечивающее корректность численных расчетов.

**Практическая значимость:** Разработка алгоритмов и программного обеспечения решения задачи по определению электромагнитных характеристик включения может быть применима для мониторинга подповерхностных слоёв дорожных конструкций, строительных участков, а также в задачах археологии. Это связано с тем, что физическое состояние подстилающих слоев (высокая влажность), наличие пустот, несомненно влияют на состояние верхних слоев, вплоть до разрушения их.

**Личный вклад диссертанта.** В рамках диссертационного исследования автором самостоятельно выполнен следующий объем научной и практической работы:

**Публикации результатов исследования.**

**1. Публикации международных рецензируемых научных журналах Web of Science Core Collection, Scopus:**

1. Deep Learning for Structural Health Monitoring of Pavements for Improving Road Maintenance and Management. Vol. 8 No. 2 (2025): Decision Making: Applications in Management and Engineering. 863-880. Индексируемом в базе Scopus, Q1 квартиль, CiteScore percentile – 89% [9].

2. Continuation problem of the electromagnetic field in the frequency domain for horizontally layred media /Eurassian Journal of Mathematical and Computer Applications/ 2024, Volume 12, Issue 3/ 105-116/ Индексируемом в базе Scopus, Q3 квартиль, CiteScore percentile – 34% [10].

**- статьи, опубликованные в научных журналах, рекомендуемых КОКСНВО МНВО РК:**

1. Gpr sounding source calibration. Вестник Национальной инженерной академии Республики Казахстан. 2024. № 2 (92) УДК 537.8+517.9 2024г. 227-233стр [11].

2. Определения глубины залегания включения в подстилающей среде. КРГТУ. Университет Еңбектері - Труды Университета №1, 2024, 519-524 с. [12]

#### **Апробация результатов исследования.**

Основные результаты диссертационной работы докладывались на семинарах и заседаниях кафедры «Информационно-коммуникационных технологий» Северо-Казахстанский университета имени Манаша Козыбаева, механико-математического факультета Новосибирского государственного университета:

Международных конференциях:

1. Определение глубины залегания включения в подстилающей среде // Матер. 15-й междунар. молод. науч. школы-конф. «Теория и численные методы решения обратных и некорректных задач». – Новосибирск, 2023. – С. 23-45. [13]

2. Проблема продолжения электромагнитного поля в частотной области для горизонтально слоистых сред // XVI международная молодежная научная школа - конференция «Определение калибровочной функции зависимости диэлектрической проницаемости от влажности». Новосибирск, Академгородок. 30 сентября-2 октября 2024 г. [14].

3. 09 февраля 2026 года на кафедре информационно-коммуникационных технологий Северо-Казахстанский университет имени Манаша Козыбаева (Петропавловск) был проведён научно-методический семинар, в рамках которого были представлены и обсуждены результаты исследования.

**- публикации, опубликованные в трудах международных конференций:**

1. XV Международная молодежная научная школа-конференция «Теория и численные методы решения обратных и некорректных задач» посвященная 85 - летию академика РАН В.Г. Романова. Институт Математики им. С.Л. Соболева СО РАН. Математический центр в Академгородке. 30 октября – 3 ноября 2023г. 23-45стр.

2. XVI международная молодежная научная школа-конференция «Определение калибровочной функции зависимости диэлектрической проницаемости от влажности». Новосибирск, Академгородок. 30 сентября-2 октября 2024 г, 86-97стр.

**- свидетельство о государственной регистрации на объект авторского права:**

1. Программа определения глубины залегания подповерхностных объектов методом георадиолокационного зондирования (программа ЭВМ). Комитет по правам интеллектуальной собственности Министерство юстиции Республика Казахстан. Запись в реестре комитета по правам интеллектуальной собственности за №65240 от 11.12.2025г. (Приложение А) [15]

**- Акт внедрения: в учебный процесс и производственные:**

1. Акт внедрения: в учебный процесс в НАО «Восточно-Казахстанский технический университет имени Д. Серикбаева» кафедра «транспортного

строительства» для студентов образовательной программы «Информатика, вычислительная техника и управление» (Приложение Б).

2. Акт о внедрении программного продукта программный продукт для ЭВМ «Программа обработки и интерпретации георадиолокационных данных для мониторинга и диагностики подповерхностных слоёв на основе алгоритмов глубокого обучения», Представители РГП на ПХВ «Национальный центр качества дорожных активов». (Приложение Б).

По теме диссертации опубликована 2 статьи в научном журнале с импакт-фактором проиндексированы в базе данных в Scopus, 2 статей в научных журналах, рекомендованных Комитетом по контролю в сфере образования и науки КОКСНВО МНВО РК, 2 тезисов международных конференций, 1 свидетельство о государственной регистрации на объект на авторского права (Приложение А) и 2 Акт внедрения результатов диссертации в учебной и производственные процессы (Приложение Б).

**Структура и объем работы.** Диссертационная работа состоит из введения, четырех разделов, заключения, списка использованных источников и приложений. Работа изложена на 118 страницах, приложения содержат 40 рисунков и 11 таблиц.

**Во введении** описана актуальность и научная значимость, цель, задачи, методы исследования.

**Первый раздел** изложены фундаментальные основы георадиолокации. Распространение электромагнитных волн в различных средах характеризуется скоростью распространения волн, диэлектрической проницаемостью среды, удельным затуханием сигнала. Электромагнитные импульсы, возникающие в результате возбуждения передающей антенны генератором наносекундных импульсов, распространяются в зондируемой среде, испытывая затухание, рассеяние и отражение на неоднородностях среды. Приемная антенна принимает данные сигналы, преобразует электромагнитный отклик в электрический сигнал, который затем фильтруется, усиливается и регистрируется приемником в аналоговом или цифровом виде. Полученный сигнал оцифровывается и передается в блок цифровой обработки (возможно компьютер), где проводится первичная обработка сигнала, запись во встроенную память для последующей обработки и визуализации.

Изложена структурная схема георадара серии «Лоза-В», которая состоит из следующих основных узлов: генератора наносекундных импульсов, стробоскопического приемника, широкополосной антенной системы с низкой дисперсией, синхронизатора, модуля интерфейса, компьютера, источника питания.

Рассмотрена задача определения глубины залегания включения в подстилающей среде. Алгоритм определения глубины залегания основан на методе зондирования с применением аппаратного средства георадар серии «Лоза-В». Существуют два метода георадарной съемки: «профилирование» и «зондирование». При профилировании радар перемещается вдоль трассы вместе с передающей и приемной антенной. При зондировании выбирается одна точка

трассы, затем проводится ряд регистраций отраженных сигналов при разносе антенн источника и приемника на равные расстояния в разные стороны. В результате этих измерений получается годограф-функция времени задержки отраженных сигналов [16]. *Как было отмечено выше метод зондирования был принят в основу наших экспериментальных измерений.* Глубина внедрения определяется на основе двух измерений задержки сигнала и известного расстояния между приемником и источником.

Использование метода георадиолокационного зондирования является одним из наиболее перспективных и динамичных направлений развития геофизических исследований. Работа георадара основана на свойстве радиоволн отражаться от границ раздела сред с различной диэлектрической проницаемостью.

Основными преимуществами метода являются высокая разрешающая способность, помехоустойчивость по отношению к искажающим сигналам, а также оперативность и экономичность. Метод георадиолокационного зондирования дает возможность детально исследовать подповерхностную структуру грунтов или техногенных конструкций, существенно уменьшая расходы на бурение контрольно-измерительных скважин.

Были проведены экспериментальные исследования на песчаном карьере близ села Сабынды, находящейся в 70 км от города Астаны по направлению в сторону райцентра «Коргалжын». Эксперимент проводился с помощью георадара серии «Лоза-В». Наш эксперимент основан на амплитудном ALG-формате, антенной длиной 50 см. Каждое измерение проводилось в нескольких точках, каждая точка дает 512 данных в бинарном формате. В каждом случае записываются данные от 0 до 99, и при  $x = 0$  равно 512 данных. Полученные амплитуды записываются с шагом 0,5 нс. На основе полученных данных радарограммы, созданы алгоритмы по переводу данных из бинарного формата в текстовый и нарисованы графики с помощью языка программирования Python.

В третьем подразделе приведен широкий обзор анализа алгоритмов и методов машинного обучения для решения задач георадиолокации, в частности рассматривается задача обеспечения долговечных и безопасных подповерхностных слоёв дорожных конструкций, имеющих решающее значение для устойчивых транспортных систем и городского развития. Модели, основанные на методах глубокого обучения, позволяют повысить эффективность управления дорожной инфраструктурой за счет прогнозирования её структурного состояния. Это даёт возможность организациям, ответственным за содержание дорог, правильно расставлять приоритеты при проведении ремонтных работ и рационально использовать ресурсы. Интеграция таких моделей с данными сенсоров и транспортных потоков в реальном времени обеспечивает превентивное, экономически эффективное и безопасное управление дорожной сетью.

В рамках исследования была проанализирована методика интерпретации данных георадиолокации (GPR), предложенная А.В. Старовойтовым [16, с. 3-150]. Выделяются четыре этапа:

Идентификация волн-помех, в котором исследуются распознавание и исключение ложных отражений; Выделение георадарных комплексов, а именно участок разреза, соответствующий определённой геологической толще; Интерпретация георадарных фаций- структурные единицы внутри комплекса, отражающие специфические условия формирования среды;

**Во втором разделе** В рамках исследования была проанализирована методика интерпретации данных георадиолокации (GPR), предложенная А.В. Старовойтовым. Выделяются четыре этапа [16, с. 10-39]:

Идентификация волн-помех, в котором исследуются распознавание и исключение ложных отражений; Выделение георадарных комплексов, а именно участок разреза, соответствующий определённой геологической толще; Интерпретация георадарных фаций- структурные единицы внутри комплекса, отражающие специфические условия формирования среды; Построение глубинного разреза, а именно переход от временного разреза по данным георадара к глубинному, то есть определения геоэлектрического разреза по слоям дорожной одежды. Преобразование временных данных в глубинные осуществляется с учётом скоростей радиоволн в различных средах. Методика Старовойтова – комплексный подход к интерпретации GPR-данных, позволяющий пошагово перейти от «сырых» радарограмм к инженерной модели среды. Приведена методика обработки экспериментальных данных георадара «Лоза-В». Результаты георадарного исследования – это георадиолокационные профили (радарограмма), содержащие отражения от границ раздела сред с различными электрофизическими параметрами. Радарограмма представляет собой набор записей сигналов (трасс), пришедших к приемной антенне в интервал времени от момента посылки зондирующего импульса до конца интервала записи. Спектр радарограммы вычисляется алгоритмами быстрого преобразования Фурье. Спектральный анализ радарограмм выполняется с целью выяснения отношений сигнал/шум.

Разработан алгоритм интерактивного способа определения геоэлектрического разреза., а именно конструкция применяемого георадара «Лоза-В» позволила разнести источник и антенну приемника, что вычислить искомые параметры. Метод зондирования является самым информативным для рассматриваемого сорта задач. Для апробации программного модуля были подготовлены в полевых условиях ряд мишеней, погруженных во вмещающую среду (чистый песок), а именно: железная канистра; пластмассовые бутылки: торфяной брикет.

Определена функциональная зависимость между диэлектрической проницаемостью геофизических свойств неоднородной среды и влажностью этих слоев. С этой целью проведен эксперимент следующего содержания. В заполненную колбу слоями из основных компонент неоднородной среды: фрагменты асфальтового покрытия; щебень различных фракций; балласт и подстилающий слой-грунт, внизу колбы нагнеталась водная струя воды.

Затем с помощью влагометра МГ4 определялась влажность состояний слоев неоднородной среды. Подача воды в колбу фиксировалась с помощью счетчика расходов воды. Были проведены серия измерений, на основе которой

экспериментально установлена функциональная зависимость. Эксперименты были проведены с целью определения значения влажности по слоям, при которых происходит расслоение слоев неоднородной среды. В дальнейшем, решая обратную задачу тем или иным способом, определив геоэлектрический разрез, учитывая связь между этими данными и степени влажности можно прогнозировать состояние неоднородности на наличие дефектов.

Экспериментально установлена зависимость диэлектрической проницаемости от влажности. Такого сорта задачи возникают при прогнозе состояния дорожного покрытия, так как из-за природных условий может происходить деформирование дорожного покрытия (вздутие, обвал верхнего слоя), как правило из-за техногенных явлений, а именно за нарушения целостности грунта, связанной повышением ее влажности.

Если влажность грунта увеличилась в следствие присутствия грунтовых вод, то относительная диэлектрическая проницаемость грунта тоже увеличится. В связи с этим нами проведены дополнительно экспериментальные исследования по определению корреляционной зависимости между влажностью грунта и ее диэлектрической проницаемости. Эксперименты были проведены на базе Восточно-Казахстанского технического университета им Д. Серикбаева. Имея значения диэлектрической проницаемости по слоям дорожной одежды на основе методики первичной обработки георадарных данных и используя экспериментально установленную зависимость диэлектрической проницаемости, можно спрогнозировать состояние влажности подстилающей среды.

На примере экспериментальных исследований, проведенных с помощью георадара «Лоза-В», изложена методика первичной обработки экспериментальных данных георадара. Все измерения проводились методом зондирования. Выбран участок песчаного карьера, однородной среды – речной песок. На этом участке (песчаный карьер), находящийся вблизи города Астаны, исследованы различные объекты. Проведена интерпретация серии радарограмм, полученных в результате экспериментальных исследований с георадаром на основе метода зондирования. Результаты этих исследований необходимы для решения коэффициентных обратных задач, а именно по определению геофизических свойств подстилающего слоя.

Такого сорта задачи возникают при прогнозе состояния дорожного покрытия, так как из-за природных условий может происходить деформирование дорожного покрытия (вздутие, обвал верхнего слоя), как правило из-за техногенных явлений, а именно за нарушения целостности грунта, связанной повышением ее влажности.

**В третьем разделе** предложена модель мониторинга структурного состояния подповерхностных слоёв дорожных конструкций, основанная на методах машинного обучения, с целью повышения эффективности обслуживания и управления дорогами. Модель использует такие параметры, как температура асфальта и толщина покрытия, для прогнозирования состояния дорожного полотна. Работоспособность модели была проверена на основе данных полевых испытаний, включая измерения с использованием тяжёлого

падающего дефлектометра и георадара. Разработанная модель обеспечивает экономичный и не нарушающий целостность покрытия способ контроля состояния дорожных конструкций и прогнозирования будущих дефектов, что помогает планировать ремонты и оптимизировать использование ресурсов. Интеграция предложенного подхода с системами умного города и умной мобильности позволяет осуществлять мониторинг в реальном времени, повышая безопасность дорожного движения и способствуя созданию устойчивых, эффективных транспортных сетей. Этот подход является ключевым шагом к формированию интеллектуальной и устойчивой городской инфраструктуры. В рамках исследования метод долгой кратковременной памяти был сопоставлен с другими методами машинного обучения. Согласно результатам, модель на основе долгой кратковременной памяти показала наилучшие характеристики как на этапе обучения, так и при тестировании, обеспечив среднеквадратичную ошибку 3,01 и коэффициент корреляции 0,92. Это подтверждает высокую точность прогнозирования и способность модели обобщать новые данные по сравнению с другими подходами. Следовательно, модель на основе долгой кратковременной памяти была выбрана как наиболее эффективный предиктор для использованного в исследовании набора данных. Полученные результаты показывают, что дорожные агентства могут полагаться на системы мониторинга структурного состояния, основанные на искусственном интеллекте, для регулярного контроля состояния подповерхностных слоёв дорожных конструкций. Кроме того, необходимо объединять данные сенсоров и транспортных потоков в централизованных платформах и разрабатывать политику поддержки прогнозного обслуживания, что позволит продлить срок службы дорог, сократить затраты и повысить безопасность для пользователей.

**Четвертый раздел** описан процесс калибровки источника зондирования георадара. Приведено математическое обоснование этого процесса, результаты калибровки по данным, измеренным на песочном карьере, где электромагнитные параметры зондирующей среды являются известными. Полученные значения параметров, характеризующие поведение источника, теперь могут считаться известными и использоваться для численного решения обратных задач по определению неизвестных электромагнитных параметров среды с использованием алгоритмов, которые не являются встроенными в математическое обеспечение георадара.

Представлен численный алгоритм определения электрических параметров подстилающего слоя неоднородной среды. На практике такого сорта задача возникает, например во время эксплуатации дорожного покрытия из-за природных условий может происходить деформирование, поднятия грунтовых вод, техногенных явлений, нарушения целостности грунта, потеря его однородности, содержания в грунте крупного инородного объекта, и т.д. Рассмотрена задача прогноза определения электромагнитных параметров грунта. Сухой грунт имеет определенную диэлектрическую проницаемость и проводимость. Если влажность грунта увеличилась в следствие присутствия грунтовых вод, то относительная диэлектрическая проницаемость грунта тоже увеличится. Имея значение диэлектрической проницаемости грунта и используя

экспериментально установленную зависимость диэлектрической проницаемости и влажности, можно определить и окончательно проводимость.

Этот подход, основан на следующих физически обоснованных положениях.

Задача определения горизонтальной компоненты электрической напряженности на некоторой глубине упрощается в тех случаях, когда электромагнитные свойства первых нескольких слоев известны, а свойства подстилающей среды подлежат определению. Нами представлен численный алгоритм определения диэлектрической проницаемости грунта-подстилающего слоя. В такой постановке отпадает необходимость решения обратной задачи оптимизационным методом. Приведены численные расчеты.

**В заключении** конце работы приводится заключение, где изложены основные результаты диссертации, выносимые на защиту. Содержание диссертации завершается списком использованных источников и приложениями.

**В приложении** практические материалы исследования.

Автор выражает глубокую благодарность своему научным консультантам к.т.н, ассоциированному профессору Курмашеву Ильдар Гусмановичу, второй научный консультант д.ф.-м.н., профессору, Исакову Казизат Такуадиновичу, зарубежному консультанту физико-математических наук профессору Amir Mosavi Aliahsraf

# 1 АНАЛИЗ АЛГОРИТМОВ И МОДЕЛЕЙ ОБРАБОТКИ ГЕОРАДИОЛОКАЦИОННЫХ ДАННЫХ

В первом разделе изложены фундаментальные основы георадиолокации. Электромагнитных волн в средах характеризуется скоростью распространения волн, диэлектрической проницаемостью среды, и проводимостью. Антенна принимает сигналы, затем электромагнитный сигнал: фильтруется; усиливается и регистрируется приемником в аналоговом или цифровом виде. Полученный сигнал передается в блок цифровой обработки, где проводится первичная обработка сигнала, для последующей обработки и визуализации.

Структурная схема георадара серии «Лоза-В» [2], которая состоит из следующих основных узлов: генератора наносекундных импульсов, стробоскопического приемника, широкополосной антенной системы с низкой дисперсией, синхронизатора, модуля интерфейса, компьютера, источника питания.

Приведена методика обработки экспериментальных данных георадара «Лоза-В» [2]. Результаты георадарного исследования профили, содержат отражения от границ раздела сред с различными электрофизическими свойствами. Радарограмма представляет собой набор записей сигналов фиксированных приемной антенной. Для дальнейшего обработки сигнала проводится спектральный анализ радарограмм с целью выяснения отношений сигнал/шум.

Рассмотрена задача определения глубины залегания включения в подстилающей среде. Алгоритм определения глубины залегания основан на методе зондирования с применением аппаратного средства георадар серии «Лоза-В» [2]. Существуют два метода георадарной съемки: «профилирование» и «зондирование» [2]. При профилировании радар перемещается вдоль трассы вместе с передающей и приемной антенной. При зондировании выбирается одна точка трассы, затем проводится ряд регистраций отраженных сигналов при разносе антенн источника и приемника на равные расстояния в разные стороны [2]. В результате этих измерений получается годограф-функция времени задержки отраженных сигналов [16, с. 3-152]. Как было отмечено выше метод зондирования был принят в основу наших экспериментальных измерений. Глубина внедрения определяется на основе двух измерений задержки сигнала и известного расстояния между приемником и источником.

Использование метода георадиолокационного зондирования является одним из наиболее перспективных и динамичных направлений развития геофизических исследований. Работа георадара основана на свойстве радиоволн отражаться от границ раздела сред с различной диэлектрической проницаемостью.

Основными преимуществами метода являются высокая разрешающая способность, помехоустойчивость по отношению к искажающим сигналам, а также оперативность и экономичность. Метод зондирования дает возможность детально исследовать подповерхностную структуру грунтов существенно уменьшая расходы на бурение контрольно-измерительных скважин.

Для определения геологического разреза подстилающей поверхности нужно провести предварительную обработку полученных данных. Одним из способов предварительной обработки радарограммы является фильтрация аппаратных шумов [17]. Для подавления шумов и помех в сигнале используются различные фильтры [18].

Были проведены экспериментальные исследования на песчаном карьере близ села Сабынды, находящейся в 70 км от города Астаны по направлению в сторону райцентра «Коргалжын». Эксперимент проводился с помощью георадара серии «Лоза-В». Наш эксперимент основан на амплитудном ALG-формате, с антеннами в развертке: длиной 50 см и 100 см. На основе полученных данных радарограммы, создан алгоритм по переводу данных из бинарного формата в текстовый и нарисованы графики.

### 1.1 Основы георадиолокации и принципы функционирования георадара «Лоза-В»

Георадиолокация – это геофизический метод обследования подповерхностной структуры подземной среды, с применением геофизического прибора - георадар. Этот прибор излучает сигнал радиочастотного диапазона и регистрирует отражения этого сигнала от различных объектов грунтовой среды [16, с. 3-152].

Структурная схема георадара состоит из основных блоков [2]: генератора наносекундных импульсов; стробоскопического приемника; широкополосной антенной системы; синхронизатора; модуля интерфейса; микроконтроллера; источника питания.

Распространение электромагнитных волн в различных средах характеризуется скоростью распространения волн, диэлектрической проницаемостью среды, удельным затуханием сигнала (значения этих параметров для основных сред приведены в таблица 1.

Таблица 1 – Электрофизические характеристики сред

Среда	Относительная диэлектрическая проницаемость $\epsilon$	Удельное затухание – А, дБ/м	Скорость распространения волн V, м/нс
Воздух	1	0	0,300
Песок влажный	20–30	0,5–5	0,055–0,067
Песок сухой	4–6	0,01–1,5	0,122–0,150
Суглинок влажный	10–20		0,067–0,095
Суглинок сухой	4–6		0,122–0,150
Глина влажная	19–27	2–20	0,058–0,069
Глина сухая	2–7	10–50	0,113–0,212
Торф	50–78		0,034–0,042
Гранит	9		0,100
Бетон сухой	3–7	1–7	0,090–0,113
Асфальт сухой	3–6	2–15	0,122–0,173
Пресный лёд	4	0,1–3,5	0,150
Пресная вода	81	0,10	0,033
Примечание – Составлено по источникам [16, с. 13-15; 17, с 13-23]			

Скорость распространения электромагнитных волн в среде определяется из соотношения [16, с. 3-152; 17, с 3-239]:

$$V = \frac{c}{\sqrt{\varepsilon_0}}, \quad (1)$$

где  $c$  – скорость света, 0,3 м/нс;

$\varepsilon_0$  – относительная диэлектрическая проницаемость среды.

Генераторная часть прибора обеспечивает возбуждение зондирующих импульсов в генераторной антенне на двух частотах - 75 и 150 МГц.





Рисунок 1 – Зондирующий сигнал колебаний

Примечание – Составлено по источникам [16, с. 13-15; 17, с 13-23]

В соответствии с рисунком 1, зондирующий сигнал имеет форму 1.5 периода колебаний. Частота излучения импульсов - 10 КГц. Изменения центральной частоты зондирующего импульса происходит за счет подключения антенн разной длины. Общая длина антенн должна быть кратна 1/2 длины волны в воздухе. Размах антенн при частоте 75 МГц составляет 2 метра ( $\lambda = 4$  м), а при частоте 150 МГц - 1 метр ( $\lambda = 2$  м).

1. Измерительная часть прибора обеспечивает регистрацию отраженных волн с приемной антенны, автоматическую временную регулировку усиления, стробирование и оцифровку сигнала.

2. Стробирование сигнала обеспечивается блоком управления и одна радаротрасса получается после излучения и стробирования 512 импульсов. На рисунок 2 приведена схема оцифровки сигнала методом стробирования.



б

Рисунок 2 – а, б - Схема оцифровки сигнала методом стробирования

Примечание – Составлено по источникам [17, с. 120; 18, с. 125]

На каждой трассе снимается значение амплитуды, соответствующее одному времени задержки. Оцифровка производится через интервал [17, с. 12-25; 18, с. 14-20]:

$$\Delta t = \frac{T_{\text{разв}}}{512}$$

где  $T_{\text{разв}}$  – время развертки (нс);

512 – число отсчетов для оцифровки одной трассы.




Рисунок 3 – Зависимость амплитуды сигнала от времени

Примечание – Составлено по источникам [17, с. 120; 18, с. 125]

В соответствии с рисунком 3, приведена амплитуда отражённого от границы сред сигнала. Общее время трассы называется временной развёрткой и для георадара «ЛЮЗА» [19] разных серий составляет: 256, 512, 1024, 2048 нс.

В результате интерпретации радарограмм, получены серии откликов сред, с применением различных антенн, которые будут использованы для решения обратных задач по восстановлению источника (Табличные значения). Проведен спектральный анализ, полученных радарограмм с применением пакета программ.

Далее, приведен пример обработки, который был проведен с помощью георадара «Люза - В». Данные были сохранены в текстовом формате (файл с расширением .txt )

Обозначение в файле:

1. X – порядковый номер измерения по профилю (0 -51200).
2. T – момент регистрации амплитудного значения сигнала (0 -256,...4096 ns) с шагом 0,5 нс.

3. ALn1 - если в настройках выбран линейный режим, значение амплитуды сигнала в диапазоне (0...32768...65535). При этом значение 32768 соответствует нулевому уровню амплитуды сигнала.

4. ALg - если в настройках установлен логарифмический режим, значение амплитуды сигнала в диапазоне 0–127 интерпретируется со смещением, при котором значение 64 соответствует нулевому уровню амплитуды сигнала.

Наш эксперимент основан на амплитудном ALG-формате, антенной с разверткой: 50 см, 100 см. Полученные амплитуды записываются с шагом 0,5 нс. На основе данных радарограммы, создан алгоритм по переводу данных из бинарного формата в текстовый и нарисованы графики.

Структурная схема георадара состоит из следующих узлов: генератора наносекундных импульсов, стробоскопического приемника, широкополосной

антенной системы с низкой дисперсией, синхронизатора, модуля интерфейса, компьютера, источника питания [19].

Конструкция георадара «Лоза - В» [2; 19], в отличие от других георадаров, разделением на автономные антенну и источник делают возможным разносить точки передачи и приема сигнала, что очень важно и расширяет возможности прибора.

Метод «зондирования» или построения годографа считается основополагающим для уточнения действительной глубины залегания объекта или подстилающего слоя, а также для определения параметров подстилающей поверхности по скорости распространения отраженного сигнала. Подобная возможность, как было отмечено выше недоступна для подавляющего большинства производимых во всем мире моделей радаров.

Существуют два основных способа георадарной съемки: «профилирование» и «зондирование» [2; 19]. При профилировании радар перемещается вдоль трассы, при каждом измерении передающая и приемная антенны находятся в одной точке трассы, или, по крайней мере, расстояние между ними постоянно и значительно меньше длины трассы.

При зондировании выбирается одна точка трассы, для которой оно будет произведено, далее проводится ряд регистраций отраженных сигналов при разносе антенн передатчика и приемника в разные стороны на равные расстояния. В результате получается годограф – функция времени задержки отраженных сигналов от расстояния между передающей и приемной антеннами.

Схема зондирования показана на рисунок 4 [19].

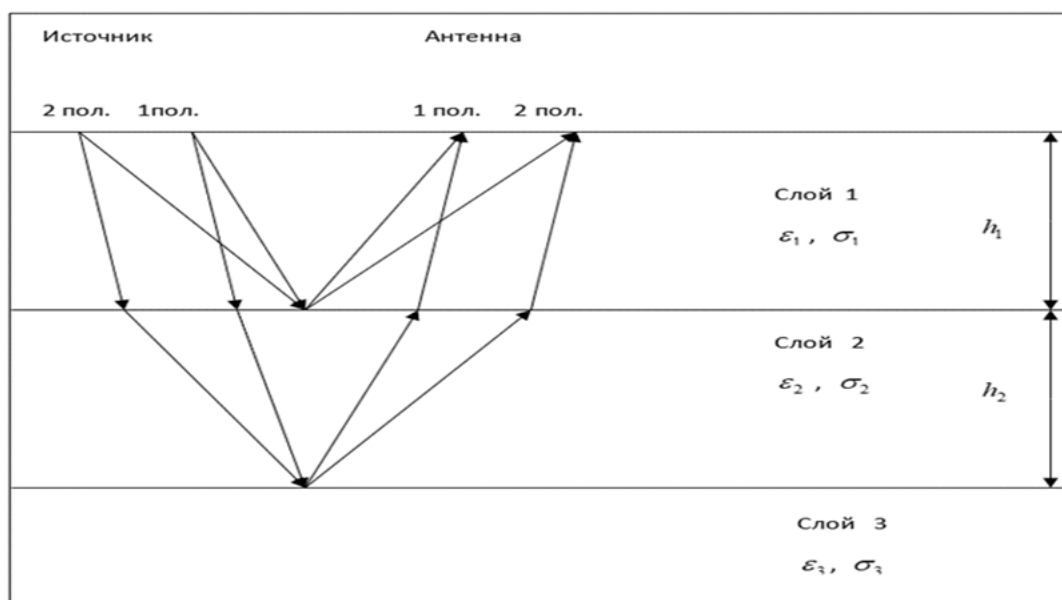


Рисунок 4 – Схема зондирования

Примечания:

1. Первоначально источник и антенна находятся на положении 1, затем на положении 2
2. Составлено по источнику [19]

Из приведенной схемы (рисунок 4) видно, что количество независимых уравнений при зондировании удваивается. Это объясняется следующими

причинами: во-первых, большое количество точек позволяет лучше идентифицировать годограф; во-вторых, увеличивается точность расчетов.

Запишем ниже уравнения для времени прихода и амплитуды импульса, отраженного от границы между первым и вторым слоем [16, с. 3-152; 17, с. 3-238].

$$t_1 = \frac{2l_1\sqrt{\varepsilon_1}}{c} \quad (2)$$

$$t_2 = \frac{2l_2\sqrt{\varepsilon_1}}{c} \quad (3)$$

$$A_1 = A_0 R_{12}(\alpha) \exp(-2p_1 l_1) \quad (4)$$

$$A_2 = A_0 R_{12}(\alpha) \exp(-2p_1 l_2) \quad (5)$$

где  $l$  – геометрическая длина пути импульса в среде от точки излучения до точки отражения, равная пути от точки отражения до точки приема [16, с. 32-39]:

$$l = \sqrt{h^2 + \frac{d^2}{4}} \quad (6)$$

Она определяется по теореме Пифагора через неизвестную толщину слоя  $h$  и известное расстояние между передатчиком и приемником  $d$ .

Проведение экспериментальных исследований георадаром «Лоза», именно методом зондирования (антенна и источник раздвигаются на равные расстояния над объектом исследования), позволяет использовать в полной мере закон Снеллиуса. Вначале определив мощности слоев, посредством геометрических формул, затем учитывая время пробега по слоям определим скорости распространения по слоям. Тем самым учитывая связь скорости и диэлектрической проницаемости и коэффициента отражения восстановить общую картину геоэлектрического разреза по слоям. Указанный способ по аналогии и применяется в задачах сейсморазведки.

Отклик получаемый в точках наблюдения георадаром именно в табличном представлении используется нами для определения геоэлектрического разреза. При методе подбора эта дополнительная информация используется для минимизации квадратичного функционала невязки рассчитанных и наблюдаемых полей. Этот метод позволяет однозначно решить задачу по восстановлению геоэлектрического разреза.

Способ измерения методом зондирования, когда можно раздвигать антенну и источник на равные расстояния над исследуемым объектом позволил решить круг задач по восстановлению геоэлектрического разреза.

По двум измерениям задержек сигнала  $t_1$  и  $t_2$  на расстояниях между приемником и передатчиком  $d_1$  и  $d_2$  однозначно определяются мощность слоя  $h_1$

и его диэлектрическая проницаемость  $\varepsilon_1$  по следующим формулам (7), (8) [16, с. 23-39]:

$$h_1 = \sqrt{\frac{t_2^2 d_2^2 - t_1^2 d_1^2}{4(t_1^2 - t_2^2)}} \quad (7)$$

$$\varepsilon_1 = \frac{t_1^2 c^2}{4h_1^2 + 2_1} \quad (8)$$

## 1.2 Метод зондирования и алгоритмы первичной обработки георадиолокационных сигналов

Задача продолжения на заданную глубину актуальна в случае, когда электромагнитные свойства верхних слоёв известны, а ниже свойства слоистой среды подлежат определению [7, с. 3-314]. Если задача продолжения решена, то обратную задачу определения неизвестных параметров среды можно сформулировать на меньшей области. Это ускоряет решение прямой задачи и, следовательно, обратной задачи.

Одним из первых технологически продвинутых алгоритмов послойного пересчёта для решения краевой задачи для дифференциального уравнения второго порядка в горизонтально-слоистой среде был алгоритм Тихонова–Шахсуварова [20]. Однако он имел ограничения: аналитические выражения содержали экспоненциальные функции с положительными действительными частями показателей, что приводило к накоплению ошибок округления при вычислениях и послойном пересчёте. Этот недостаток был устранён в работах Дмитриева (см., например, [21, 22]), где были использована идея вычислительных выражений Гельфанда и Локуциевского [23] для решения краевой задачи дифференциального уравнения второго порядка, что позволило получить устойчивые к накоплению ошибок округления выражения.

В дальнейшем метод послойного пересчёта был развит для решения систем дифференциальных уравнений второго порядка: для систем уравнений теории упругости (горизонтально-слоистая изотропная среда [24-26], изотропная среда с поглощением [27, 28], трансверсально-изотропная среда с осью симметрии, совпадающей с осью Oz [29], среды с произвольной анизотропией [30, 31]), для уравнений Максвелла (горизонтально-слоистая среда с произвольной анизотропией [31, с. 23-60; 32]), для системы уравнений конвективного тепло- и влагопереноса [33], а также для дифференциального уравнения четвёртого порядка поперечных колебаний кусочно-однородной балки [34]. В настоящее время метод послойного пересчёта для решения краевых задач дифференциальных уравнений второго порядка или их систем в горизонтально-слоистых средах считается одним из наиболее эффективных для вычислений [35].

Численное решение задач продолжения, как правило, является неустойчивым и требует применения методов регуляризации (см., например, [36-42]).

Двумерные и трёхмерные задачи продолжения поля в стационарном случае математически формулируются как задача Коши для эллиптического

уравнения, а в нестационарном случае – как задача для параболического или гиперболического уравнения с данными на времеподобной границе. Для численного решения задачи Коши для эллиптического уравнения предложено множество методов (см., например, обзор в работе [43]).

Для уравнений с данными на времеподобной границе известны лишь два метода – метод оптимизации [43, р. 220-225] и метод сопряжённого оператора [44]. Как правило, предлагаемые методы решения задачи Коши (см. [42, р. 628-638]) тестировались на моделируемых данных; в работах [44, р. 4-19; 45-47] задача решалась на данных лабораторных экспериментов. Также решение параболического уравнения с данными на времеподобной границе было получено после лабораторных измерений [47, р. 803-805; 48]. Некоторые простые постановки задач продолжения поля приведены в [49, 50].

### **1.3 Численные алгоритмы и методы машинного обучения для решения задач георадиолокации**

Компоненты мониторинга структурного состояния применяются на ранних этапах планирования и проектирования дорожной инфраструктуры, а также в процессе строительства, планирования мобильности, транспортного моделирования и последующих работ по техническому обслуживанию [51, 52]. Традиционные методы оценки состояния дорожного покрытия часто ограничены высокими эксплуатационными затратами, логистическими сложностями и риском нарушения дорожного движения, что в совокупности снижает их пригодность для управления инфраструктурой на больших территориях [53]. В последние годы всё большее распространение получают подходы на основе машинного обучения, направленные на преодоление этих ограничений и устранение выявленных исследовательских пробелов [54, 55]. Такие модели обычно включают важные переменные, такие как температура поверхности асфальта и глубина слоёв дорожного покрытия, включая асфальтовый слой, основание и подоснование, каждая из которых влияет на структурную реакцию и функциональное поведение дорожного покрытия [56]. Прогностические возможности машинного обучения используются для формирования проактивного и эффективного планирования технического обслуживания, что способствует более рациональному распределению ресурсов и повышению безопасности дорожного движения [57]. Интеграция мониторинга структурного состояния в более широкие концепции умных городов (smart city) и интеллектуальной мобильности (smart mobility) рассматривается как стратегия управления городской инфраструктурой, основанная на адаптивных и ориентированных на данные подходах [58]. Интеллектуальная мобильность, направленная на оптимизацию перемещения людей и грузов с использованием передовых технологических решений, в значительной степени выигрывает от точной оценки состояния дорожного покрытия в режиме реального времени.

Предлагаемая концепция интеллектуального мониторинга структурного состояния способна усилить развитие интеллектуальных транспортных систем, поскольку оперативная оценка состояния дорожного покрытия способствует более эффективному управлению дорожным движением, оптимизации

маршрутов и адаптивному планированию технического обслуживания [59]. Данная методология обеспечивает развитие дорожной сети в соответствии с более широкими целями интеллектуальной мобильности, формируя транспортные системы, которые являются безопасными, устойчивыми и эффективными с операционной точки зрения. Таким образом, система интеллектуального мониторинга структурного состояния рассматривается как ключевой элемент совершенствования управления дорожными покрытиями и признаётся важной составляющей программ умных городов и интеллектуальной мобильности [60]. Она предлагает масштабируемый и экологически ответственный подход к управлению инфраструктурой, способствуя формированию городских сред, устойчивых и способных адаптироваться к потребностям как нынешнего, так и будущих поколений.

До появления технологий искусственного интеллекта мониторинг структурного состояния в значительной степени основывался на традиционных методах, таких как ручные инспекции и процедуры прямого тестирования [61]. Эти процессы включали проверку конструкций на наличие видимых признаков разрушения, включая трещины и коррозию. Для наблюдения за реакцией конструкций на приложенные нагрузки проводились статические и динамические испытания [62]. Изменения напряжений фиксировались с помощью тензодатчиков, тогда как скрытые внутренние дефекты выявлялись с использованием акустической эмиссии и ультразвуковых исследований [63]. Мониторинг изменений вибрационных характеристик часто применялся для выявления изменений жёсткости конструкции, тогда как радиографические методы, основанные на использовании рентгеновского и гамма-излучения, позволяли проводить внутреннюю диагностику [64]. Георадар (ground penetrating radar) использовался для анализа состояния подповерхностных слоёв Bernard и Yakovenko [65], а инфракрасная термография позволяла выявлять поверхностные дефекты путём фиксации температурных контрастов [66, 67]. Системы дорожного покрытия также анализировались с использованием дефлектометров падающего груза (falling weight deflectometer), которые имитировали давление, возникающее под воздействием транспортных нагрузок [68]. Хотя эти методы предоставляли ценную информацию, они не обладали достаточной прогностической способностью. Подповерхностные или ранние стадии дефектов часто оставались незамеченными, а многие процедуры требовали значительных эксплуатационных перерывов, что делало мониторинг сложным и неэффективным. Искусственный интеллект, включая машинное обучение и глубокое обучение, изменил структурный ландшафт мониторинга структурного состояния, поскольку позволяет быстро и непрерывно интерпретировать большие объёмы данных в режиме реального времени [68, p. 104784]. Традиционные подходы ограничены трудоёмкими инспекциями, дорогостоящим оборудованием и ограниченными аналитическими возможностями, вследствие чего ранние признаки разрушения часто остаются незамеченными, а оценка состояния конструкций проводится лишь эпизодически [69]. Искусственный интеллект совершенствует процессы мониторинга за счёт непрерывного анализа данных, получаемых от датчиков,

изображений и исторических архивов, что позволяет проводить точные и перспективные оценки состояния инфраструктуры. Методы машинного обучения дают возможность прогнозировать будущие процессы деградации и потребности в техническом обслуживании, тогда как глубокое обучение выявляет мелкомасштабные повреждения на изображениях, полученных с дронов, или в потоках данных датчиков, которые традиционные методы обычно не способны обнаружить [70]. Подобные системы постепенно совершенствуются по мере накопления новых данных, что снижает зависимость от ручных инспекций, уменьшает расходы на обслуживание и способствует увеличению срока службы инфраструктуры. В управлении дорожными активами искусственный интеллект особенно полезен, поскольку позволяет осуществлять неинвазивный мониторинг в режиме реального времени, отслеживая влияние транспортных потоков, изменения окружающей среды и усталость материалов без остановки движения транспортных средств. Прогнозирование потребностей в техническом обслуживании заранее обеспечивает своевременное проведение ремонтных работ, повышает безопасность дорожного движения и увеличивает срок эксплуатации транспортных сетей. Такие разработки помогают городам продвигаться к интеллектуальным системам мобильности и способствуют формированию устойчивых моделей городского развития [71]. Ряд исследований демонстрирует эти преимущества. Например, в работе Alnaqbi и др. [72] применялись алгоритмы машинного обучения, такие как деревья решений, случайные леса и метод опорных векторов, для прогнозирования деградации гибких подповерхностных слоёв дорожных конструкций на основе исторических данных о состоянии покрытия, информации о транспортных потоках и климатических переменных. Эти модели показали, что тенденции разрушения могут быть выявлены на ранних стадиях, что позволяет инженерам планировать восстановительные мероприятия и продлевать срок службы дорожного покрытия. В другом исследовании искусственные нейронные сети использовались для оценки остаточного срока службы асфальтовых покрытий [73]. Используя данные обследования подповерхностных слоёв дорожных конструкций, образцы керна и информацию об экологических условиях, модель предоставила надёжные показатели необходимости обслуживания и способствовала оптимизации графиков ремонтных работ. Метод опорных векторов (Support Vector Machines) также применялся для прогнозирования эксплуатационных характеристик и остаточного срока службы жёстких дорожных покрытий [72, p. 146]. Дополнительные исследования, например Ali и др. [74], интегрировали данные индекса состояния дорожного покрытия (PCI), транспортные нагрузки и свойства материалов, что позволило получить надёжные прогнозы эксплуатационных характеристик и более эффективно расставлять приоритеты при проведении ремонтных работ. Отдельная система мониторинга в режиме реального времени анализировала данные, полученные от акселерометров и датчиков прогиба, размещённых в структуре дорожного покрытия [75]. Эта система фиксировала реакцию покрытия на погодные условия и транспортные нагрузки, что позволяло раньше выявлять структурные проблемы и снижать нарушения дорожного движения. Подходы глубокого

обучения, в частности свёрточные нейронные сети (CNN), использовались для обработки данных георадара (GPR) при оценке состояния подповерхностных слоёв дорожных конструкций [76]. Эти методы успешно выявляли подповерхностные аномалии, такие как пустоты и трещины, что улучшало прогнозирование деградации подповерхностных слоёв дорожных конструкций и поддерживало планирование технического обслуживания. Крупномасштабные платформы Big Data, интегрированные с технологиями искусственного интеллекта, также были разработаны для создания прогностических систем обслуживания подповерхностных слоёв дорожных конструкций. Эти платформы используют обширные наборы данных, включая структуру транспортных потоков, метеорологические данные и исторические показатели эксплуатации покрытий [77], что повышает точность прогнозирования деградации и обеспечивает своевременное и эффективное распределение ресурсов на техническое обслуживание.

Несколько европейских стран уже внедрили системы управления дорожными покрытиями на основе искусственного интеллекта для прогнозирования их деградации и совершенствования стратегий обслуживания [78]. Эти системы интегрируют данные датчиков, транспортные нагрузки, метеорологические условия и исторические сведения о дорожных покрытиях, что позволяет точнее определять приоритеты ремонтных работ, снижать неожиданные сбои и способствовать долгосрочному обновлению инфраструктуры. В результате формируются более устойчивые и надёжные дорожные сети. Данные примеры показывают, что искусственный интеллект существенно трансформирует мониторинг структурного состояния подповерхностных слоёв дорожных конструкций (SHM), поскольку значительно улучшается прогнозирование эксплуатационных характеристик и оценка остаточного срока службы (RSL). Кроме того, методы машинного обучения (ML), глубокого обучения (DL) и аналитики больших данных обеспечивают непрерывный мониторинг, раннее выявление дефектов и оптимизацию графиков технического обслуживания, что в совокупности способствует увеличению срока службы дорожных сетей, снижению эксплуатационных расходов и укреплению устойчивых транспортных систем [78, p. 497-521]. Несмотря на значительный потенциал искусственного интеллекта в прогнозировании состояния подповерхностных слоёв дорожных конструкций и остаточного срока службы (RSL), сохраняется ряд исследовательских ограничений [79]. Многие существующие модели испытывают трудности с обобщением результатов, поскольку они калибруются для конкретных климатических, географических или эксплуатационных условий и не могут надёжно применяться в других средах. Точность прогнозирования также снижается из-за неполной интеграции релевантных источников данных, таких как подробные профили транспортных потоков, длительные метеорологические наблюдения и экологические показатели. Кроме того, передовые методы искусственного интеллекта, включая глубокое обучение (DL) и обучение с подкреплением, пока используются не в полной мере. Ещё одним ограничением является недостаточное представление неопределённости. Деградация подповерхностных слоёв дорожных конструкций

обусловлена непредсказуемыми факторами, такими как изменения интенсивности транспортных нагрузок или резкие погодные колебания. Эти аспекты часто игнорируются существующими моделями искусственного интеллекта, что подчёркивает необходимость применения квантования неопределённости и вероятностного моделирования для повышения надёжности прогнозов [80].

Современные системы искусственного интеллекта во многом функционируют как «чёрные ящики», предоставляя ограниченное понимание того, каким образом формируются прогнозы. Это создаёт проблемы прозрачности и снижает уровень доверия со стороны инженеров и лиц, принимающих решения. Недостаточная интеграция между системами мониторинга структурного состояния (SHM) на основе искусственного интеллекта и системами управления дорожными покрытиями (PMS) также ограничивает практическое применение прогнозов при непосредственном планировании технического обслуживания. Для устранения этих недостатков предлагаются гибридные модели, системы непрерывного обучения и улучшенные стратегии сбора данных. Подобные усовершенствования способны повысить эффективность проактивного планирования технического обслуживания и способствовать увеличению срока службы дорожной инфраструктуры. Последние достижения в области искусственного интеллекта, машинного обучения и глубокого обучения значительно продвинули методы оценки состояния подповерхностных слоёв дорожных конструкций. Глубокое обучение, особенно с использованием сверточных нейронных сетей (CNN), демонстрирует высокую точность при выявлении трещин и других видов повреждений [81]. Инструменты, включающие геопривязанные изображения и геопространственное картографирование, обеспечивают пространственный контекст за счёт точного определения местоположения дефектов, что позволяет выполнять более быстрые и точные ремонтные вмешательства [82].

В совокупности эти технологии направляют развитие мониторинга структурного состояния подповерхностных слоёв дорожных конструкций к более быстрому, интеллектуальному и надёжному системам. Методы машинного обучения (ML) продолжают трансформировать процессы анализа эксплуатационных характеристик и обнаружения повреждений, обрабатывая крупномасштабные наборы данных в режиме реального времени и превосходя ручные методы как по эффективности, так и по надёжности [83]. Ряд развивающихся технологий также обладает потенциалом для решения существующих проблем SHM. Ожидается, что интеграция искусственного интеллекта с аналитикой больших данных улучшит мониторинг подповерхностных слоёв дорожных конструкций за счёт преобразования больших потоков сенсорных данных в практические рекомендации по техническому обслуживанию [84]. Генеративно-состязательные сети (GAN) исследуются как инструмент для создания синтетических наборов данных для обучения моделей машинного обучения, что помогает преодолеть проблему ограниченности реальных данных – распространённое препятствие в приложениях SHM [85]. Интеграция искусственного интеллекта и Интернета

вещей (IoT) дополнительно расширяет возможности мониторинга в реальном времени, используя данные датчиков, таких как акселерометры и GPS-устройства, для выявления аномалий и более точной оценки состояния дорожного покрытия [86]. Тем не менее практическая применимость этих технологий зависит от стоимости их внедрения, частоты сбора данных и сложности реализации, что требует тщательной оценки для обеспечения долгосрочной устойчивости систем [87].

Несмотря на значительный прогресс, сохраняется ряд моделирующих проблем. Характеристика методов искусственного интеллекта как «чёрного ящика» по-прежнему затрудняет интерпретируемость, ответственность и доверие пользователей. Текущие исследования, направленные на повышение прозрачности и объяснимости моделей, стремятся устранить эти ограничения [88]. Экологическая и эксплуатационная изменчивость также остаётся серьёзной проблемой, поскольку модели искусственного интеллекта могут демонстрировать нестабильные результаты при изменении условий, таких как колебания погодных параметров, температурные изменения или вариации интенсивности дорожного движения. В связи с этим существует потребность в устойчивых моделях, способных адаптироваться к таким динамическим входным данным для поддержания надёжной работы систем мониторинга структурного состояния [89]. Междисциплинарный подход, объединяющий технологические инновации и практические аспекты внедрения, является необходимым условием для того, чтобы системы мониторинга структурного состояния подповерхностных слоёв дорожных конструкций на основе искусственного интеллекта смогли полностью реализовать свой потенциал в поддержке эффективного и устойчивого технического обслуживания дорожной инфраструктуры.

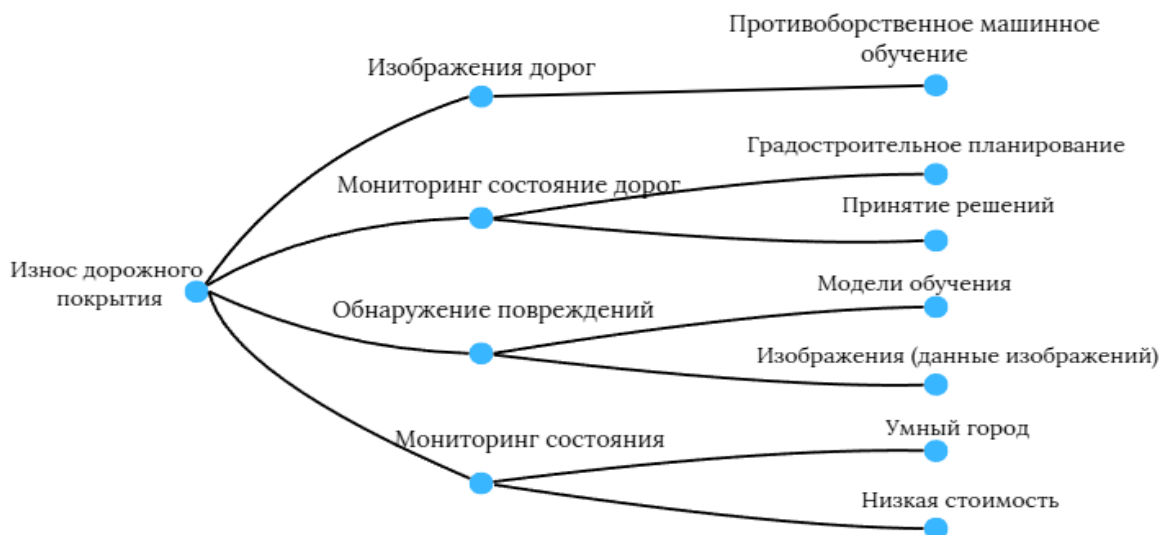


Рисунок 5 – Таксономия приложения машинного обучения для моделирования дорожного покрытия

Методы машинного обучения (ML) всё чаще рассматриваются как

ключевой инструмент для прогнозирования остаточного срока службы (RSL) подповерхностных слоёв дорожных конструкций, а их интеграция в системы управления дорожными покрытиями (PMS) повышает точность и эффективность планирования технического обслуживания, предоставляя аналитические возможности, превосходящие традиционные методы оценки [87, p. 213]. Подходы на основе регрессионного анализа показали высокую надёжность при оценке характеристик сцепления асфальтового покрытия García-Segura и другое [90]. В то же время более сложные методы машинного обучения, такие как Random Forest (случайный лес), демонстрируют значительное повышение точности при прогнозировании роста шероховатости покрытия, образования колеи и усталостного растрескивания [60, p. 4-14]. Модели метода опорных векторов (SVM) и искусственных нейронных сетей (ANN) также демонстрируют высокие прогностические возможности, причём ANN часто обеспечивают более точные оценки параметров, связанных с шероховатостью дорожного покрытия [91].

В области глубокого обучения (DL) модели, такие как YOLOv5 и U-Net, достигают высокой точности при обнаружении и сегментации трещин дорожного покрытия [92]. Анализ временных рядов эффективно выполняется с использованием архитектур RNN и LSTM, при этом гибридные конфигурации, например LSTM-FCNN, стабильно превосходят традиционные методы моделирования [93]. Интегрированные системы, такие как SOS-LSSVR, дополнительно повышают точность прогнозирования за счёт сочетания оптимизационных алгоритмов и регрессионных методов [94]. Эти методы, основанные на искусственном интеллекте, способствуют более эффективному управлению инфраструктурными активами за счёт оптимизации графиков технического обслуживания, увеличения срока службы дорожных покрытий и снижения общих затрат на ремонт [95]. Интеграция искусственного интеллекта с системами непрерывного сбора данных в режиме реального времени дополнительно ускоряет процессы оценки состояния дорожного покрытия и позволяет проводить более ранние и целенаправленные ремонтные мероприятия [86, p. 69-88]. Тем не менее сохраняется ряд ограничений, особенно связанных с трудоёмкой разметкой данных и ограниченной способностью моделей надёжно адаптироваться к различным климатическим, конструктивным и эксплуатационным условиям [71, p. 225]. Поэтому необходимы дальнейшие исследования, направленные на внедрение искусственного интеллекта на всех этапах жизненного цикла управления дорожными покрытиями - от проектирования систем до долгосрочного технического обслуживания, что позволит расширить практическое применение этих технологий и обеспечить устойчивое повышение эффективности дорожной инфраструктуры.

Как показано на рисунке 6, методы глубокого обучения играют ключевую роль в развитии прогнозирования эксплуатационных характеристик подповерхностных слоёв дорожных конструкций. Архитектуры, такие как RNN и LSTM, демонстрируют высокую эффективность при анализе временных рядов, позволяя прогнозировать изменения состояния дорожного покрытия, тогда как модели CNN эффективно выявляют и классифицируют дефекты дорожного

покрытия [96].



Рисунок 6 – Таксономия приложений глубокого обучения в моделировании дорожного покрытия

Эти методы повышают точность прогнозирования процессов разрушения и модуля упругости покрытия, что способствует более надёжной оценке надёжности дорожного покрытия и общего срока его службы [97]. Дополнительные преимущества обеспечивает ансамблевое обучение, объединяющее несколько стратегий моделирования. Методы, такие как Random Forest Regression (RFR) и Gradient Boosting Machine (GBM), показали высокую эффективность при прогнозировании тенденций деградации дорожного покрытия и учёте различных механизмов его разрушения [98]. Глубокие ансамблевые модели, объединяющие нейронные сети и алгоритмы на основе деревьев решений, повышают точность прогнозирования показателей, таких как шероховатость поверхности и образование трещин. Такие подходы способствуют разработке целевых мер технического обслуживания и укреплению оптимизации программ управления дорожными покрытиями. Несмотря на эти преимущества, сохраняются существенные проблемы, включая ограниченную доступность данных и внутреннюю сложность объединения различных типов моделей. Подходы, такие как аугментация данных и гибридные методы, объединяющие регрессионное моделирование с физически обоснованными представлениями процессов, могут способствовать снижению влияния этих ограничений. Соответственно, предлагаемая структура исследования подчёркивает применение надёжных принципов моделирования, направленных на формирование точных, практико-ориентированных и эффективных прогнозов срока службы подповерхностных слоёв дорожных конструкций, что способствует развитию устойчивых практик технического обслуживания и долгосрочной устойчивости инфраструктуры [99-102].

## 1.4 Методика интерпретации реальных радарограмма

Методика предложенная М.Л. Владов, А.В. Старовойтовым [16, с. 3-152] применяется для археологических, инженерно-геологических и стратиграфических задач, обеспечивая поэтапную расшифровку радарограмм. Выделяются четыре ключевых этапа:

*1 Шаг. Очистка сигнала от шумов и ложных отражений (рисунок 7).*



Рисунок 7 – Шаг 1

Корректное удаление этих помех – основа достоверной интерпретации, особенно в условиях плотной застройки, археологических памятников или инженерных объектов.

*2. Шаг. Определение георадарных фаций (рисунок 8).*



Рисунок 8 – Шаг 2

3. *Шаг. Анализ фаций* (рисунок 9).

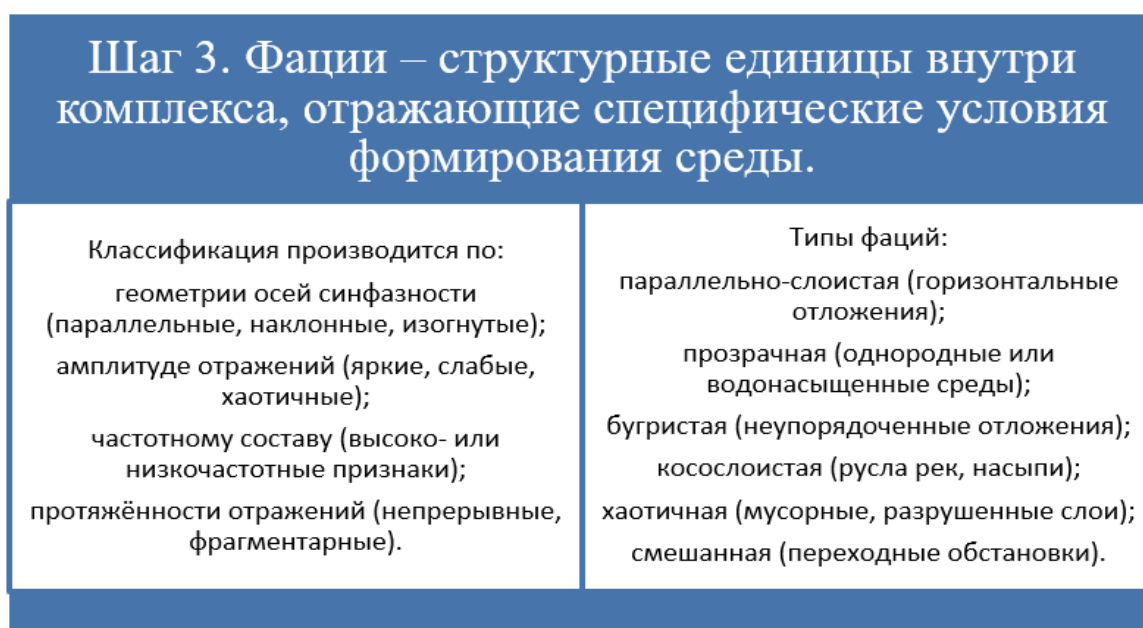


Рисунок 9 – Шаг 3

Переход от временного разреза к глубинному производится за счет определения скоростей распространения волн по средам. Так как время пробега известно по слоям, а мощность слоев определяется за счет методика измерения методом зондирования. Последнее свойственнр только георадару сери «Лоза».

4. *Шаг. От временного разреза к глубинному*

Переход от временного разреза к глубинному производится за счет определения скоростей распространения волн по средам. Время пробега известно по слоям, а мощность слоев определяется за счет методика измерения методом зондирования. Последнее свойственнр только георадару сери «Лоза»; (рисунок 10).

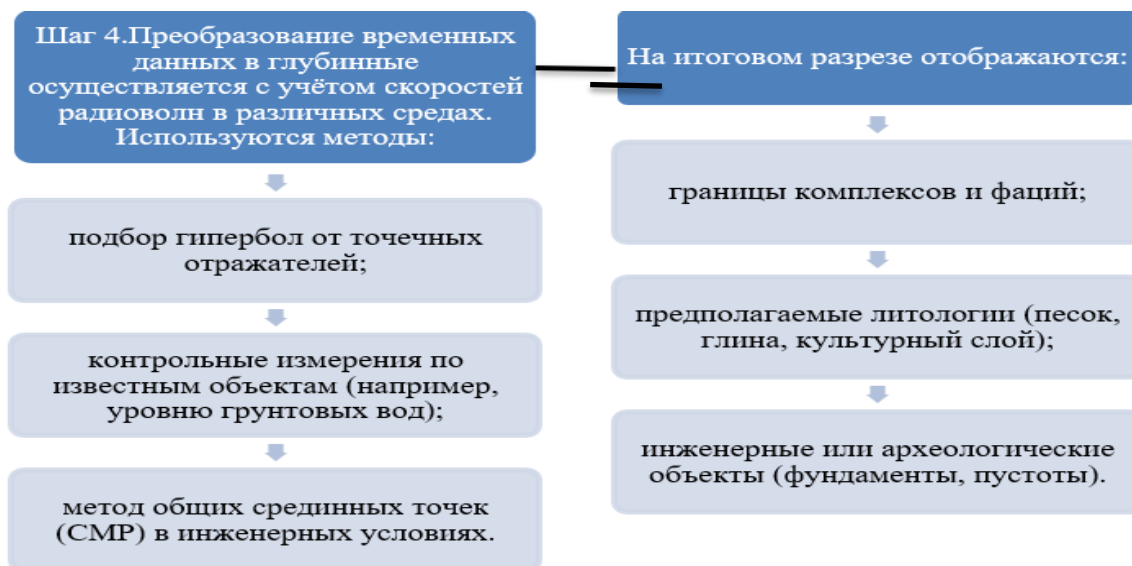


Рисунок 10 – Шаг 4

Используются методы: подбор гипербол от точечных отражателей; контрольные измерения по известным объектам (например, уровню грунтовых вод); метод общих срединных точек (СМР) в инженерных условиях.

Правильность полученной интерпретации радарограмм возможно дополнительным исследованием в лабораторных условиях кернов, или прямым вскрытием участка.

Для интерпретации радарограмм также используется алгоритм изложенный в работе [21], который позволяет перейти от первоначальных данных измерения получить модель средив, то есть геоэлектрический разрез среды, включая и геометрию слоев неоднородной среды.

Методика Старовойтова – комплексный подход к интерпретации GPR-данных, позволяющий пошагово перейти от «сырых» радарограмм к стратиграфической и инженерной модели среды. Георадиолокация, также как и сейсморазведка, является волновым методом [16, с. 3-152], поэтому основные методические приемы, которые используются при геологической интерпретации сейсмических данных, стали применяться и при анализе данных георадиолокации. В сейсморазведке эта методика, разработанная для поиска нефтегазовых ловушек, получила название сейсмической стратиграфии [17, с. 3-238].

Анализ публикаций как отечественных, так и зарубежных исследователей показывает, что самые незначительные изменения волновой картины на радарограммах обусловлены теми или иными особенностями строения разреза.

При интерпретации георадиолокационных данных выделим два основных направления. Первое связано с поиском разнообразных объектов естественного, так и искусственного происхождения. К первым относятся трубопроводы различного назначения, кабели, коллекторы, карстовые пустоты, археологические объекты и т.д. Второе направление связано с детальным изучением разреза – литологии, структуры отложений, гидрогеологических особенностей и т.д.

Анализ волновой картины начинается с выделения осей синфазности отраженных волн, которые не связаны с наличием реальных границ в разрезе, а являются волнами-помехами. Если таковые имеются, то их необходимо исключить из дальнейшего рассмотрения.

После обработки и выделения волн-помех радарограммы готовы к интерпретации. Целью интерпретации георадиолокационных данных в самом общем виде является либо детальное расчленение разреза, либо поиск или обнаружение разнообразных объектов. Детальное изучение разреза основано на тех же методических приемах, которые были разработаны и опробованы в сейсморазведке при поиске ловушек нефти и газа неструктурного типа [2].

Данная методика разделения разреза весьма успешно применяется и при анализе георадиолокационных данных. Выделенные при этом комплексы можно называть георадарными [16, с. 3-152; 17, с. 3-238].

После выделения на радарограммах комплексов часто возникает необходимость в более детальном изучении их внутреннего строения. При интерпретации сейсмических данных эта методика получила название сейсмофациального анализа [16, с. 3-152]. В геологии под фацией понимаются отложения определенных условий или ландшафтов, т. е. геологических тел тех или иных ландшафтно-генетических типов (вопрос об определении фации достаточно сложный и неоднозначный, см. [16, с. 3-152; 17, с. 3-238].

Экспериментальные исследования были проведены на песчаном карьере вблизи города Астаны по направлению Кургальджинской трассы. Для проведения эксперимента был использован георадар серии «Лоза-В», имеющий диапазон рабочих частот 50-300 МГц, и антенны с разверткой: 0,5 м; 1 м; 1,5 м и 3 м. Для исследования выбран метод зондирования, так как в этом случае можно определить мощности слоев неоднородной среды. Данный георадар имеет лицензионное программное обеспечение «Крот-NS» [20].

Первоначальная обработка сырых данных георадара были обработаны по методике профессора М.Л. Владов, А.В. Старовойтова [16, с. 3-152]. Нами предложена способ использования этой методики и соответствующих необходимых функций программного обеспечения, что является трудоемкой задачей и требует специализированного подхода и навыков геофизических обработок реальных данных. Проведены экспериментальные исследования на песчаном карьере с использованием георадара «Лоза-В». Использован метод зондирования, в котором антенна и источник раздвигаются на равные расстояния от центра лежащего предполагаемого объекта на карьере. Обработаны по предложенной выше методике два объекта: железная канистра и купол торфа, лежащие в песке на известной глубине. В данном случае это необходимо для

тестирования нашей методики исследования. Ниже по шагам приведены все важные этапы обработки сырых реальных данных до конечного результата, а именно переход от временного разреза к геоэлектрическому разрезу.

### **Выводы к первому разделу**

*В первом разделе* изложены фундаментальные основы георадиолокации. Распространение электромагнитных волн в различных средах характеризуется скоростью распространения волн, диэлектрической проницаемостью среды, удельным затуханием сигнала. Электромагнитные импульсы испускаемые источником георадара распространяются в неоднородную среду испытывая при этом отражение, рассеяние и затухание на неоднородных средах. В георадарном комплексе имеется антенна которая фиксирует эти электромагнитные отклики от неоднородных сред. Как правило с физической точки зрения оно является тангенциально компонентой вектора электрической напряженности.

Изложена структурная схема георадара серии «Лоза-В», которая состоит из следующих основных узлов: генератора наносекундных импульсов, стробоскопического приемника, широкополосной антенной системы с низкой дисперсией, синхронизатора, модуля интерфейса, компьютера, источника питания.

Как было отмечено выше метод зондирования был принят в основу наших экспериментальных измерений. Глубина внедрения определяется на основе двух измерений задержки сигнала и известного расстояния между приемником и источником.

Использование метода георадиолокационного зондирования является одним из наиболее перспективных и динамичных направлений развития геофизических исследований. Работа георадара основана на свойстве радиоволн отражаться от границ раздела сред с различной диэлектрической проницаемостью.

Основными преимуществами метода являются высокая разрешающая способность, помехоустойчивость по отношению к искажающим сигналам, а также оперативность и экономичность. Метод георадиолокационного зондирования дает возможность детально исследовать подповерхностную структуру грунтов или техногенных конструкций, существенно уменьшая расходы на бурение контрольно-измерительных скважин.

Мониторинг структурного состояния и прогностический анализ подповерхностных слоёв дорожных конструкций играют ключевую роль в обеспечении безопасности, долговечности и функциональной эффективности дорожных сетей, которые лежат в основе современных транспортных систем

Методика Старовойтова – комплексный подход к интерпретации GPR-данных, позволяющий пошагово перейти от «сырых» радарограмм к стратиграфической и инженерной модели среды. Каждый этап – от удаления помех до построения глубинного разреза – вносит вклад в достоверную расшифровку структуры подповерхностных объектов.

Геологическая интерпретация проводится в четыре этапа. На первом этапе необходимо убедиться, что все выделяемые оси синфазности отраженных волн на радарограммах являются полезными отражениями, т. е. связаны с реальными отражающими границами в разрезе.

На втором проводится выделение основных элементов разреза, которые получили название георадарных комплексов.

Третий этап заключается в детальном анализе волновой картины внутри выделенных георадарных комплексов – т.е. выделяются и анализируются так называемые георадарные фации.

На заключительном четвертом этапе производится построение глубинного геологического разреза, на котором могут отображаться инженерно-геологические и гидрогеологические особенности строения. На этом этапе обработки большое значение имеет изучение скоростных особенностей разреза для достоверного определения мощностей отдельных толщ.

## 2 ИНТЕРПРЕТАЦИЯ ГЕОРАДИОЛОКАЦИОННЫХ ДАННЫХ

В данном разделе на примере экспериментальных исследований, проведенных с помощью георадара «Лоза-В», изложена методика первичной обработки экспериментальных данных георадара. Все измерения проводились методом зондирования. Выбран участок песчаного карьера, однородной среды – речной песок. На этом участке (песчаный карьер), находящийся вблизи города Астаны, исследованы различные объекты. Проведена интерпретация серии радарограмм, полученных в результате экспериментальных исследований с георадаром на основе метода зондирования. Результаты этих исследований необходимы для решения коэффициентных обратных задач, а именно по определению геофизических свойств подстилающего слоя.

Такого сорта задачи возникают при прогнозе состояния дорожного покрытия, так как из-за природных условий может происходить деформирование дорожного покрытия (вздутие, обвал верхнего слоя), как правило из-за техногенных явлений, а именно за нарушения целостности грунта, связанной повышением ее влажности.

В рамках исследования была проанализирована методика интерпретации данных георадиолокации (GPR), предложенная М.Л. Владов, А.В. Старовойтовым [16, с. 3-152]. Выделяются четыре этапа:

Идентификация волн-помех, в котором исследуются распознавание и исключение ложных отражений; Выделение георадарных комплексов, а именно участок разреза, соответствующий определённой геологической толще; Интерпретация георадарных фаций- структурные единицы внутри комплекса, отражающие специфические условия формирования среды; Построение глубинного разреза, а именно переход от временного разреза по данным георадара к глубинному, то есть определения геоэлектрического разреза по слоям дорожной одежды. Преобразование временных данных в глубинные осуществляется с учётом скоростей радиоволн в различных средах. Методика Старовойтова – комплексный подход к интерпретации GPR-данных, позволяющий пошагово перейти от «сырых» радарограмм к инженерной модели среды.

Разработан алгоритм интерактивного способа определения геоэлектрического разреза., а именно конструкция применяемого георадара «Лоза-В» позволила разнести источник и антенну приемника, что вычислить искомые параметры. Метод зондирования является самым информативным для рассматриваемого сорта задач. Для апробации программного модуля были подготовлены в полевых условиях ряд мишеней, погруженных во вмещающую среду (чистый песок), а именно: железная канистра; пластмассовые бутылки; торфяной брикет.

Определена функциональная зависимость между диэлектрической проницаемостью геофизических свойств неоднородной среды и влажностью этих слоев. С этой целью проведен эксперимент следующего содержания. В заполненную колбу слоями из основных компонент неоднородной среды: фрагменты асфальтового покрытия; щебень различных фракций; балласт и

подстилающий слой-грунт, внизу колбы нагнеталась водная струя воды.

Затем с помощью влагометра МГ4 определялась влажность состояний слоев неоднородной среды. Подача воды в колбу фиксировалась с помощью счетчика расходов воды. Были проведены серия измерений, на основе которой экспериментально установлена функциональная зависимость. Эксперименты были проведены с целью определения значения влажности по слоям, при которых происходит расслоение слоев неоднородной среды. В дальнейшем, решая обратную задачу тем или иным способом, определив геоэлектрический разрез, учитывая связь между этими данными и степени влажности можно прогнозировать состояние неоднородности на наличие дефектов.

## 2.1 Первичная обработка реальных данных георадара

*Визуализация радарограмм состоит из следующих этапов [12, с. 519-523], вначале проведем для объекта (торф):*

Исследуем объект купол торфа (см. рисунок 7)



Рисунок 11 – Купол торфа

Примечание – Составлено по источнику [12, с. 520]

Рассматриваемый участок интерпретируется как возможный купол торфа, который характеризуется высокой проницаемостью и способностью поглощать сигнал. 38-зондирование 50 см антенной шаг 10 см. Проведено георадарное зондирование с антенной 50 см и шагом съёмки 10 см, что обеспечивает достаточную детализацию подповерхностной структуры. Проведем пошагово интерпретацию радарограммы по вышеуказанному алгоритму (рисунки 12, 13, 14, 15, 16, 17, 18):

### 1. Загрузка файла (рисунок 12).

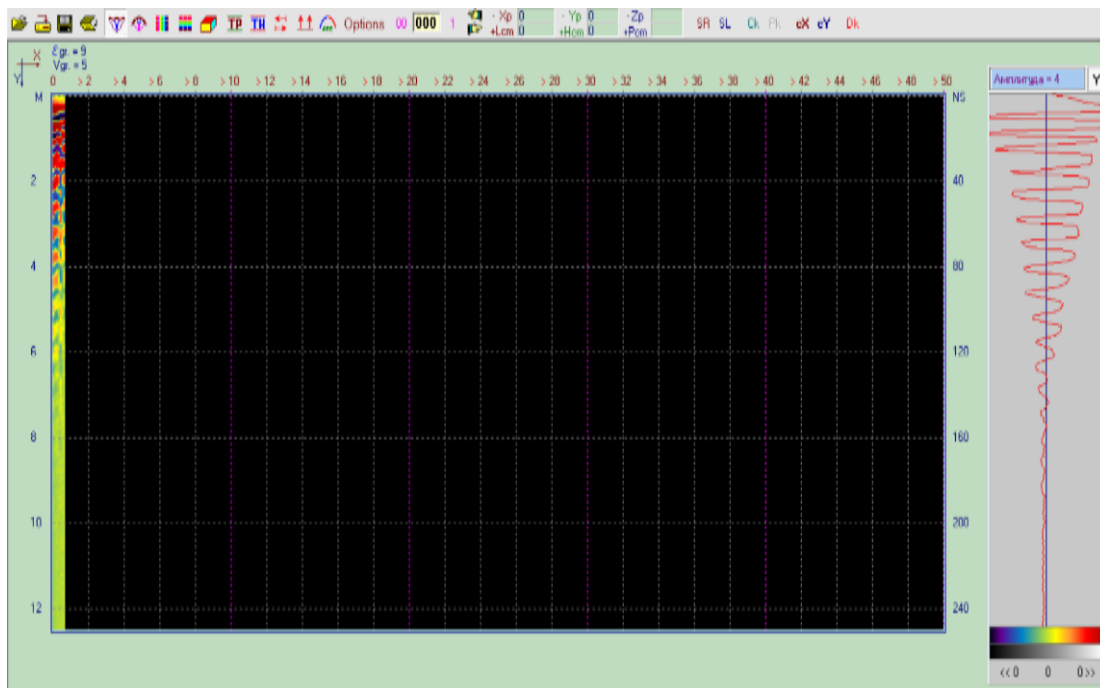


Рисунок 12 – Полученные в ходе измерений данные загружены в программное обеспечение для дальнейшей обработки и анализа

Примечание – Составлено по источнику [12, с. 521]

### 2. Расширяем радиограмму через Sx-масштабирование по оси X (рисунок 13).

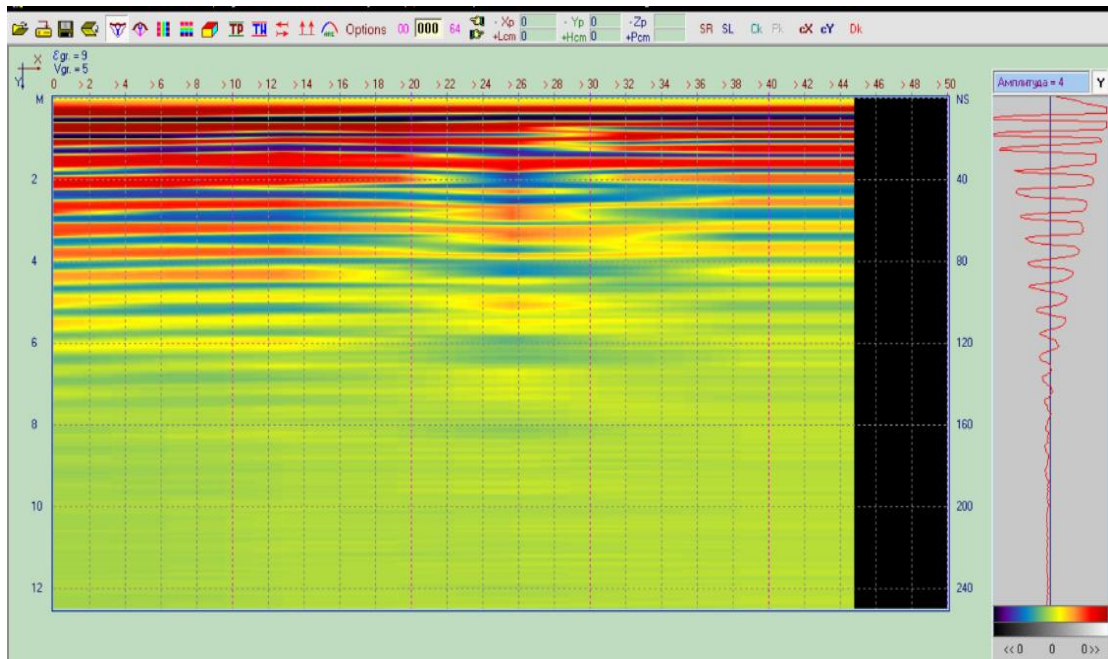


Рисунок 13 – Радиограмма увеличена по горизонтали для более детального рассмотрения слоёв и аномалий

Примечание – Составлено по источнику [12, с. 521]

### 3. Настраиваем профиль (рисунок 14).




Рисунок 14 – Выполнена корректировка параметров профиля (яркость, контраст, масштаб), что позволяет лучше визуализировать отражённые сигналы

Примечание – Составлено по источнику [12, с. 523]

### 4. Применяем НЧ2 (низкочастотный фильтр с инверсией), (рисунок 15).




Рисунок 15 – Применён низкочастотный фильтр для подавления шумов и усиления полезного сигнала, инверсия помогает лучше выделить границы объектов

Примечание – Составлено по источнику [12, с. 523]

5. Выставляем  $V_{gr}$  - скорость распространения сигнала в среде вручную на 1.6 (рисунок 16).

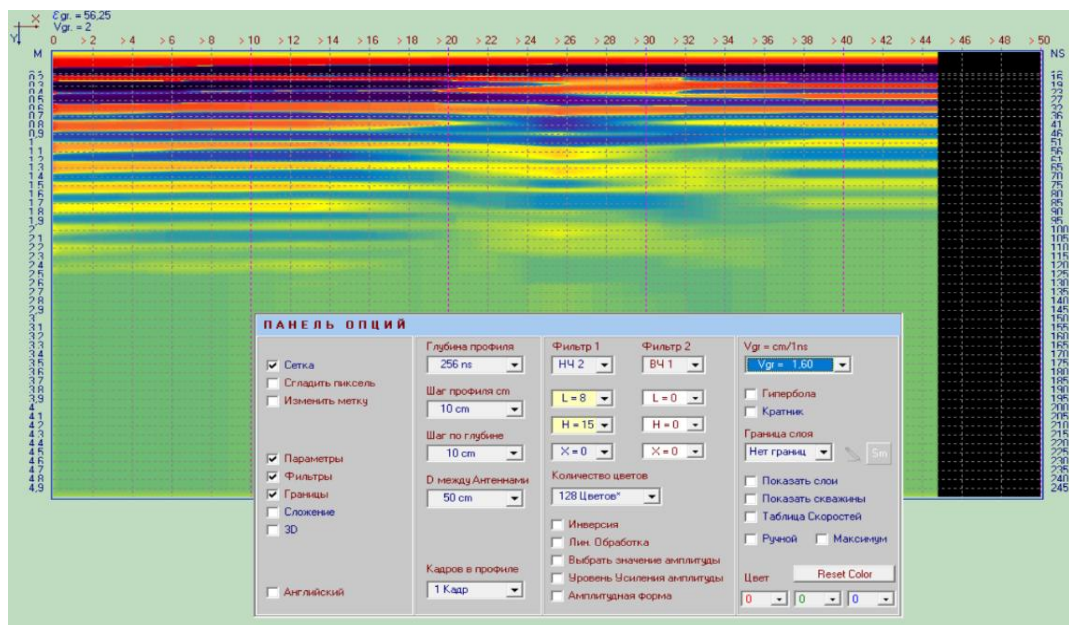


Рисунок 16 – Скорость распространения сигнала установлена вручную (1.6), что необходимо для корректного определения глубины и формы объектов

Примечание – Составлено по источнику [12, с. 523]

На кадре видна аномалия между 20 и 32

Применим высокочастотную фильтрацию что бы убрать отраженные помехи (рисунок 17).

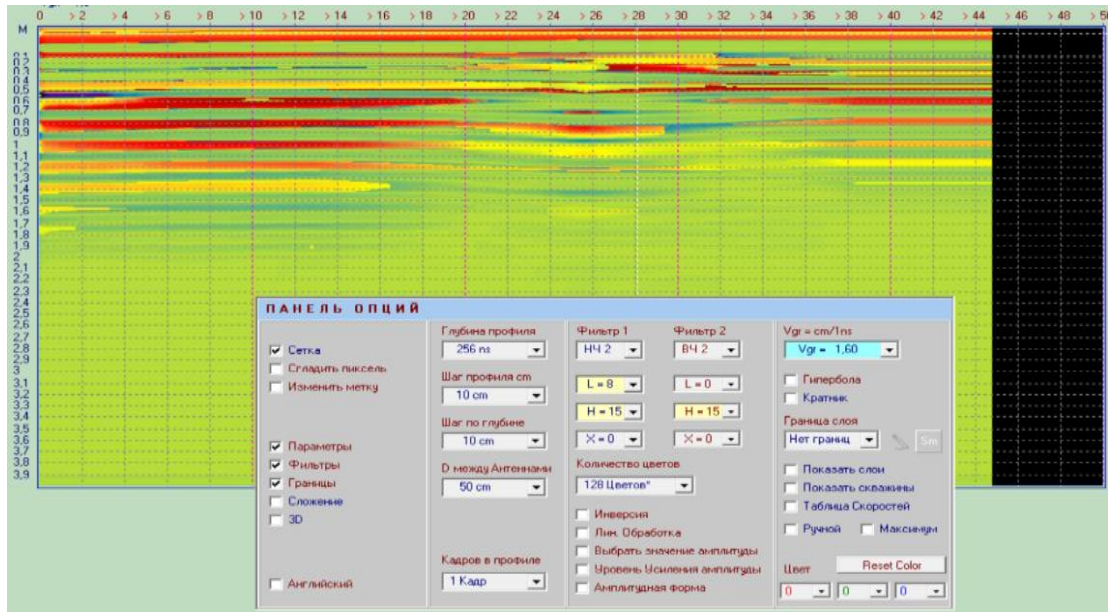


Рисунок 17 – Добавлена высокочастотная фильтрация для удаления отражённых помех и повышения чёткости изображения

Примечание – Составлено по источнику [12, с. 523]

Аномалия похожая на купол торфа видна на 22-30 (рисунок 18).

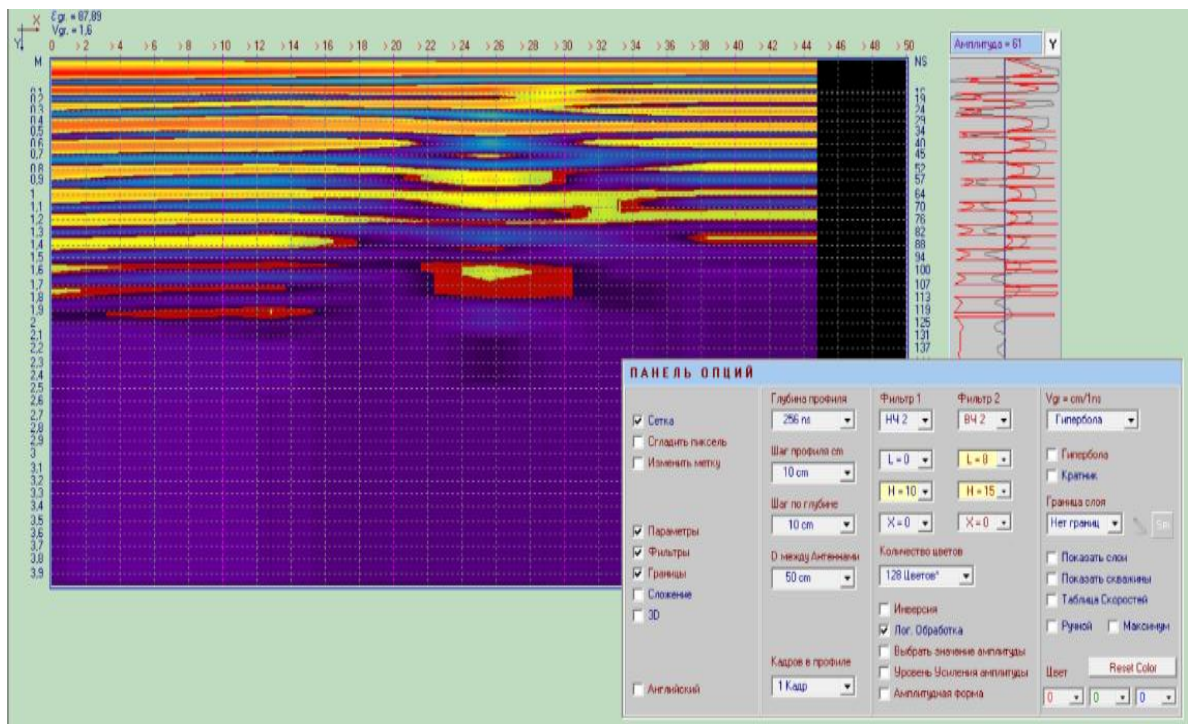


Рисунок 18 – После обработки более точно определена зона аномалии (22–30), по форме и сигналу соответствующая куполу торфа

Примечание – Составлено по источнику [12, с. 523]

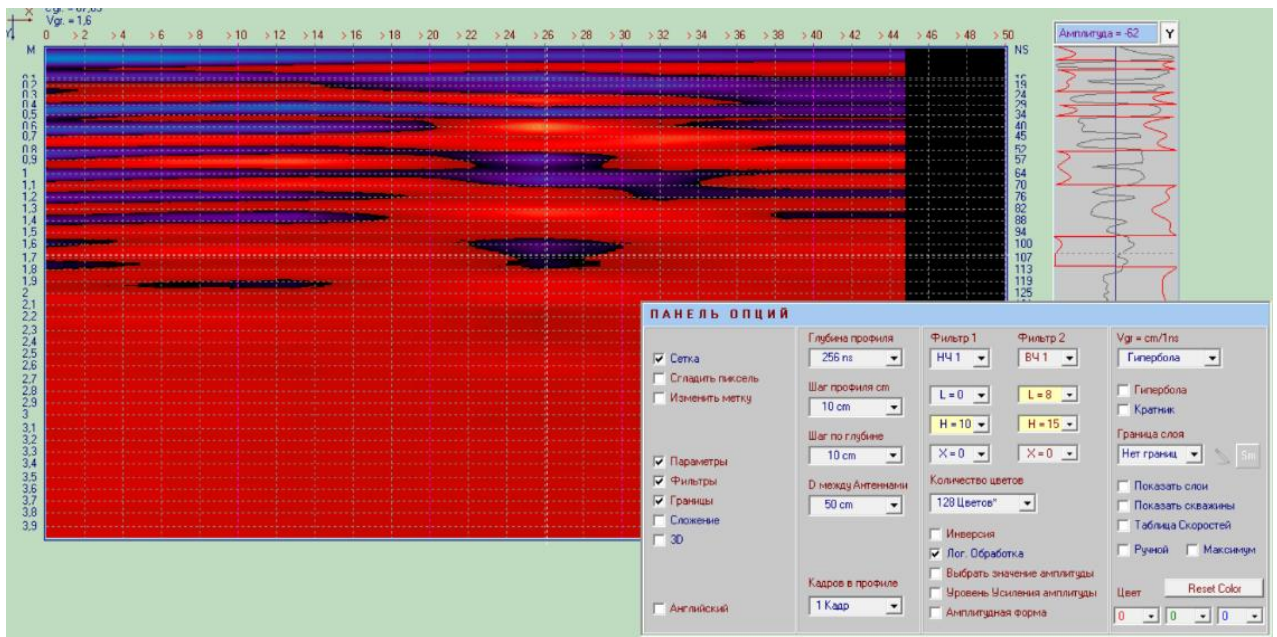


Рисунок 19 – Уменьшена фильтрация низких частот и усилена обработка высоких частот, что позволило лучше выявить структуру объект

Примечание – Составлено по источнику [14, с. 89]

В соответствии с рисунком 19, уменьшена фильтрация низких частот добавлена фильтрация по отраженным высоким частотам (предположительно купол торфа поглощает сигнал и что бы увидеть пустоту в сигнале мы должны меньше фильтровать низкие частоты).

При обработке было выявлено что при нахождение объекта с высокой проницаемостью объект больше поглощает и нужно фильтровать высокие частоты низкие оставлять.

Далее рассмотрим объект-железная канистра.

Детали исследования этого объекта по аналогии как для предыдущего объекта можно найти в (Приложении В).

Приведем окончательный результат исследования.

Аномалия между 10 и 22. Применяем высокочастотную фильтрацию, пробуем убрать отраженные волны, и применяем логарифмическую функцию для нормализации объекта (рисунок 20).

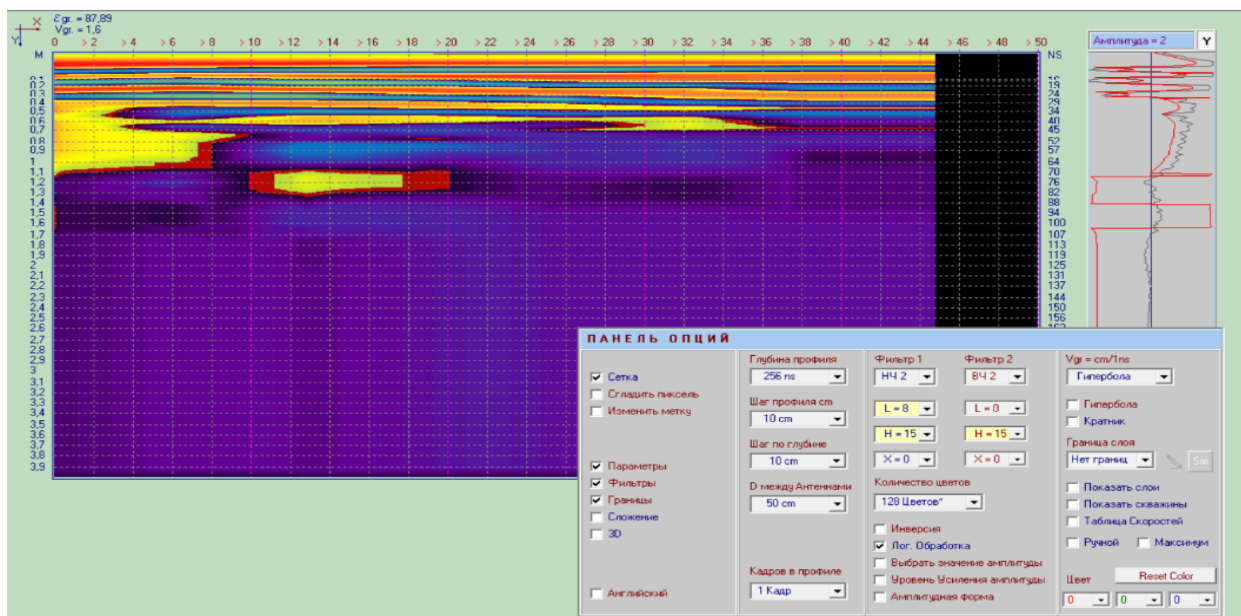


Рисунок 20 – Нормализация объекта

Примечание – Составлено по источнику [14, с. 90]

Виден объект на позиции 12-18 предположительно канистра.

Таким образом, на радарограмме виден локальный объект, а именно железная канистра. На рисунке 21 представлено расположение объекта железной канистры на глубине, порядка 1 метра.



Рисунок 21 – Железная канистра в однородной среде

Примечание – Составлено по источнику [12, с. 523]

*Вывод по обработке.* В процессе анализа установлено, что объекты с высокой проницаемостью (например, торф) сильнее поглощают сигнал. Поэтому

для их обнаружения важно уменьшать влияние низкочастотной фильтрации и уделять больше внимания высокочастотной обработке.

## **2.2 Интерактивные способы определения геоэлектрического разреза**

Данный подраздел посвящен задаче определения глубины залегания включения в подстилающей среде. Алгоритм определения глубины залегания основан на методе зондирования с применением аппаратного средства георадар серии «Лоза - В» [19]. Как было отмечено выше метод зондирования был принят в основу наших экспериментальных измерений. Глубина внедрения определяется на основе двух измерений задержки сигнала и известного расстояния между приемником и источником.

Использование метода георадиолокационного зондирования является одним из наиболее перспективных и динамичных направлений развития геофизических исследований. Работа георадара основана на свойстве радиоволн отражаться от границ раздела сред с различной диэлектрической проницаемостью.

Наиболее важными параметрами, характеризующими возможности применения метода георадиолокации в различных средах, являются удельное затухание и скорость распространения электромагнитных волн в среде, которые определяются ее электрическими свойствами. Первый из них определяет глубинность зондирования используемого георадара, знание второго параметра необходимо для пересчета временной задержки отраженного импульса в глубину до отражающей границы [19].

Для определения геологического разреза подстилающей поверхности нужно провести предварительную обработку полученных данных. Одним из способов предварительной обработки радарограммы является фильтрация аппаратных шумов [17, с. 3-236]. Для подавления шумов и помех в сигнале использовался полосовой фильтр Баттерворта. Расчет цифрового фильтра Баттерворта проведен на основе билинейного преобразования [18, с. 3-318].

Алгоритм определения глубины залегания основан на методе зондирования с применением аппаратного средства георадар серии «Лоза-В». При зондировании выбирается одна точка трассы, затем проводится ряд регистраций отраженных сигналов при разносе антенн источника и приемника на равные расстояния в разные стороны [19]. В результате этих измерений получается годограф–функция времени задержки отраженных сигналов [3, с. 3-280]. По двум измерениям задержек сигнала  $t_1$  и  $t_2$  и по известным расстояниям между приемником и источником  $d_1$  и  $d_2$  определяется глубина залегания включения из следующего соотношения (18)-(19) [16, с. 13-56]:

Тогда по известной мощности первого слоя, мы можем определить и диэлектрическую проницаемость вмещающей среды из соотношения (19):

Конструкция применяемого георадара «Лоза-В» позволила разнести источник и антенну приемника, что позволило по времени задержки и расстояния разноса определить годограф и тем самым вычислить искомые параметры. Таким образом, метод зондирования является самым информативным для рассматриваемого сорта задач. Для апробации программного модуля был

подготовлен в полевых условиях ряд мишеней, погруженных во вмещающую среду (чистый песок),

а именно: железная канистра; пластмассовые бутылки: торфяной брикет. Результаты экспериментальных исследований с применением георадара серии «Лоза-В», методом зондирования дали положительный результат.

Экспериментальные исследования

Для апробации алгоритма определения глубины залегания различных неоднородностей во вмещающей среде были подготовлены различные мишени на лабораторном полигоне на песчаном карьере в окрестности Астаны близ поселка Сабынды. Перечень мишеней: торфяной брикет; железная канистра; пустые пластмассовые бутылки; пластиковые бутылки (с водой). Все указанные мишени помещены во вмещающуюся среду-чистый песок [13, с. 23-44].

Перейдем к детальному описанию мишеней:

Объект 1. Железная канистра. Глубина залегания канистры 45 см, см. [13, с. 23-44].

Объект 2. Брикет торфа. Был использован брикет нейтрализованного торфа, объемом 60 литров. В вырытую прямоугольную яму размером 110 см в глубину и 60 см в ширину помещен торфяной купол. Высота купола составляет 30 см. Диаметр основания купола 55 см. Объект показан [13, с. 23-44].

Объект 3. Две пластиковые бутылки, заполненные водой (имитация трубопровода), см. [13, с. 23-44]. Глубина ямы 60 см, длина 155 см, ширина 80 см. Объект находится над поверхностью порядка 35 см.

Объект 4. Две пластмассовые канистры находятся на глубине 35 см. Размеры ямы ширина ямы 70 см, длина ямы 80 см. Глубина ямы 45 см, см. [13, с. 23-44].

Расчет глубины залегания подповерхностного объекта в программе осуществляется по формуле (8) и относительной диэлектрической проницаемости среды по формуле (9). Параметры и результаты расчета приведены в [13, с. 23-44]. Относительная погрешность вычисления определяемых параметров геологического разреза находится в пределах 5-8%.

Вкладка очистки трасс радарограммы от высокочастотных шумов представлена на рисунке 30. Вкладка расчета представлена на рисунке 8. После ввода пользователем относительной диэлектрической проницаемости среды программа вычисляет электрическую проводимость  $\nu$  (рисунок 9) по следующей формуле (9):

$$\sigma = a\sqrt{\varepsilon \setminus 1.69}, \quad (9)$$

где  $\alpha$  – коэффициент затухания;

$\sigma$  – проводимость;

$\varepsilon$  – диэлектрическая проницаемость.



а



б



в



г

а – яма для размещения объекта; б – купол торфа на глубине ямы; в – георадарное исследование с прибором серии «Лоза-В», методом зондирования; г – размеры основания купола, с разносом антенн

Рисунок 27 – а, б, в, г – Результаты проведенных исследований

Вкладка очистки трасс радарограммы от высокочастотных шумов представлена на рисунке 27. Вкладка расчета представлена [13, с. 23-44]. После ввода пользователем относительной диэлектрической проницаемости среды программа вычисляет электрическую проводимость  $\nu$  [13, с. 23-44] по

следующей формуле (9):

$$\sigma = a\sqrt{\varepsilon \cdot 1.69}, \quad (9)$$

где  $\alpha$  – коэффициент затухания;

$\sigma$  – проводимость;

$\varepsilon$  – диэлектрическая проницаемость.

Далее рассмотрены ниже следующие объекты (рисунок 28).



а – две пластиковые бутылки; б – две пластмассовые канистры; в – железная канистра

Рисунок 28 – а, б, в – Объект для проведения экспериментов

Для обнаружения объекта георадиолокационным методом необходимо, чтобы объект заметно отличался от вмещающего грунта по электрическим характеристикам (по диэлектрической проницаемости или проводимости).

#### *Описание программы*

Программа определения геоэлектрического разреза дополняет и улучшает интерпретацию результатов георадарных исследований с помощью фирменных ПО, поставляемых вместе с георадарами (рисунки 29, 30, 31).

Функциональные возможности программы:

1. Ввод данных из файла радарограммы.
2. Фильтрация трасс радарограммы.
3. Определение глубины залегания подповерхностного объекта.
4. Определение относительной диэлектрической проницаемости среды.
5. Определение электрической проводимости подповерхностной среды.
6. Просмотр графика трассы радарограммы.

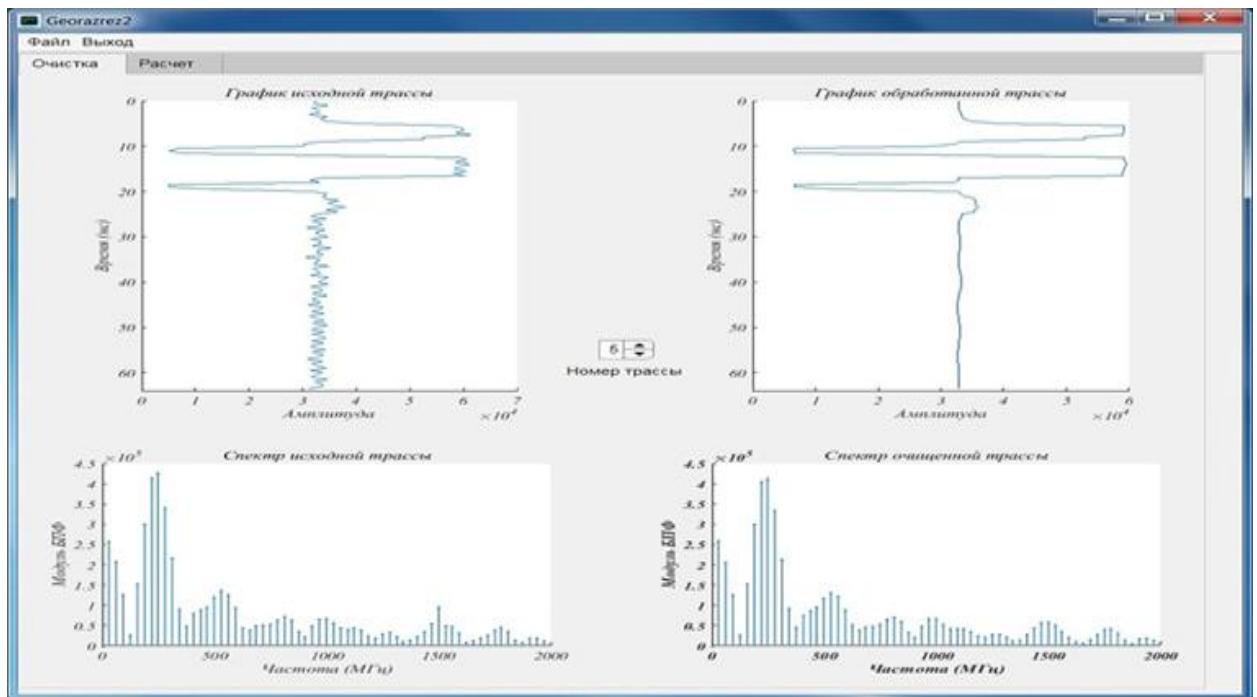


Рисунок 29 – Вкладка очистки трасс радарограммы

Примечание – Составлено по источнику [11, с. 226]

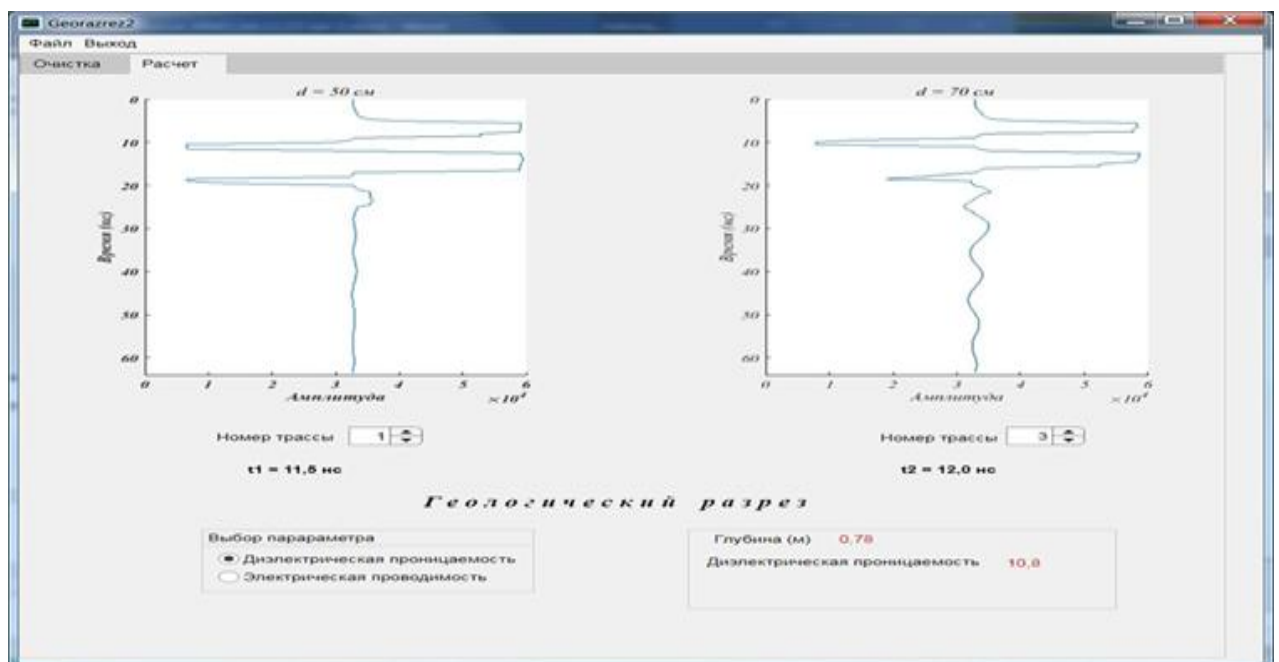


Рисунок 30 – Вкладка расчета глубины залегания подповерхностного объекта и относительной диэлектрической проницаемости среды

Примечание – Составлено по источнику [11, с. 226]

Сохранение графика трассы радарограммы в различных форматах.

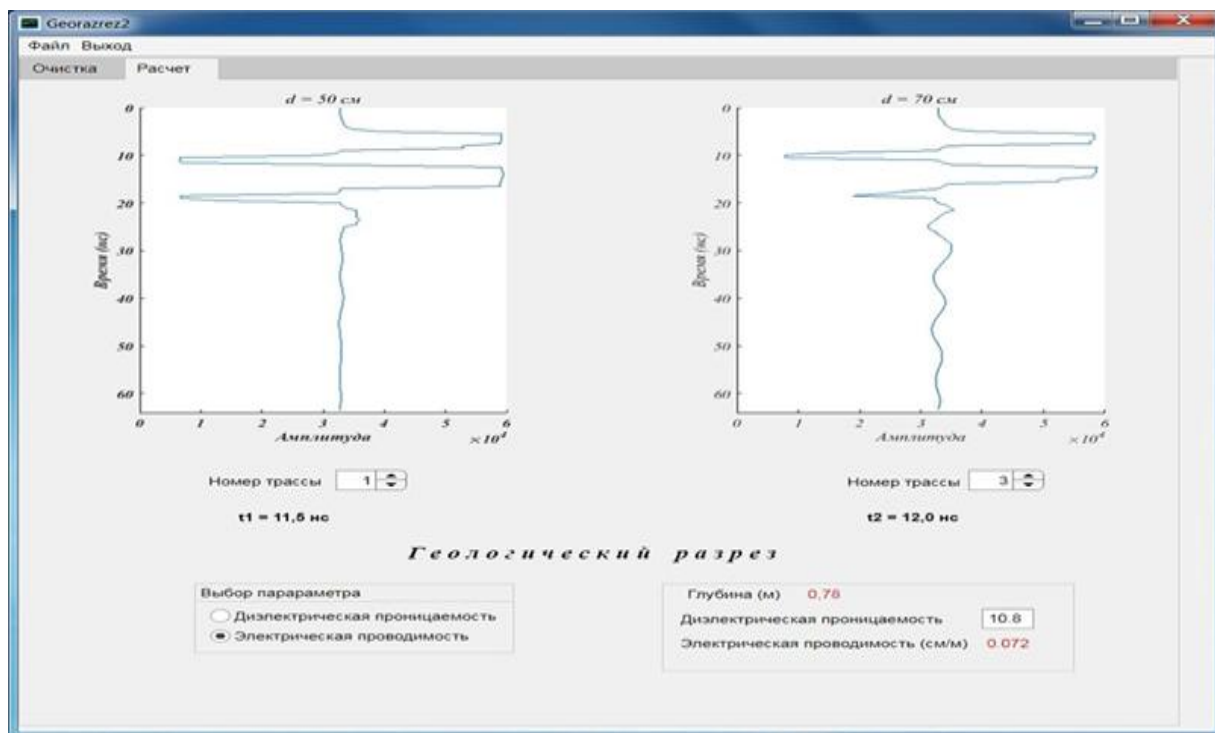


Рисунок 31 – Расчет электрической проводимости среды

Примечание – Составлено по источнику [11, с. 226]

Таблица 4 – Результаты расчета

	$d_1$ (м)	$d_2$ (м)	$t_1$ (нс)	$t_2$ (нс)	$h$ (м)
Объект 1	0,5	0,7	11,5	12	0,783
Объект 2	0,5	0,6	6,5	7	0,33
Объект3	0,5	0,8	4,5	5,5	0,37

$d_1$  (м) — расстояние от георадара до первого отражающего слоя или объекта в метрах.

$d_2$  (м) — расстояние от георадара до второго отражающего слоя или объекта в метрах.

$t_1$  (нс) — время прохождения сигнала до первого слоя и обратно, в наносекундах (нс).

$t_2$  (нс) — время прохождения сигнала до второго слоя и обратно, в наносекундах (нс).

$h$  (м) — глубина залегания объекта или слоя, вычисленная на основе времени прохождения сигнала и диэлектрических свойств среды, в метрах.

### **2.3 Определение зависимости электрической проницаемости от влажности**

В данном подразделе на примере экспериментальных исследований, проведенных с помощью георадара «Лоза-В», изложена методика первичной обработки экспериментальных данных георадара. Выбран участок песчаного карьера, однородной среды - речной песок. На этом участке (песчаный карьер), находящийся вблизи города Астаны, исследованы различные объекты. Использован метод зондирования, в котором антенна и источник раздвигаются на равные расстояния от центра лежащего предполагаемого объекта на карьере. Проведена интерпретация серии радарограмм, полученных в результате экспериментальных исследований с георадаром. Результаты этих исследований необходимы для решения коэффициентных обратных задач, а именно по определению геофизических свойств подстилающего слоя.

Такого сорта задачи возникают при прогнозе состояния дорожного покрытия, так как из-за природных условий может происходить деформирование дорожного покрытия (вздутие, обвал верхнего слоя), как правило из-за техногенных явлений, а именно за нарушения целостности грунта, связанной повышением ее влажности.

Если влажность грунта увеличилась в следствие присутствия грунтовых вод, то относительная диэлектрическая проницаемость грунта тоже увеличится. В связи с этим нами проведены дополнительно экспериментальные исследования по определению корреляционной зависимости между влажностью грунта и ее диэлектрической проницаемости. Эксперименты были проведены на базе Восточно-Казахстанского технического университета им Д. Серикбаева.

В рамках исследования была проанализирована методика интерпретации данных георадиолокации (GPR), предложенная А.В. Старовойтовым [16, с. 3-152]. Выделяются четыре этапа:

Идентификация волн-помех, в котором исследуются распознавание и исключение ложных отражений; Выделение георадарных комплексов, а именно участок разреза, соответствующий определённой геологической толще; Интерпретация георадарных фаций- структурные единицы внутри комплекса, отражающие специфические условия формирования среды; Построение глубинного разреза, а именно переход от временного разреза по данным георадара к глубинному, то есть определения геоэлектрического разреза по слоям дорожной одежды. Преобразование временных данных в глубинные осуществляется с учётом скоростей радиоволн в различных средах. Методика Старовойтова – комплексный подход к интерпретации GPR-данных, позволяющий пошагово перейти от «сырых» радарограмм к инженерной модели среды.

Первичная обработка георадарных данных.

Интерпретация радарограмм проводится по следующему алгоритму. На первом шаге выделяем оси синфазности отраженных волн на радарограммах, которые являются полезными отражениями. На втором выделяем георадарные

комплексы. Третий шаг состоит в детальном анализе волновой картины внутри георадарных комплексов, то есть выделяем георадарные фации. И наконец на четвертом шаге производится построение глубинного геологического разреза, на котором могут отображаться инженерно-геологические и гидрогеологические особенности строения. На этом шаге обработки большое значение имеет определение скоростных характеристик разреза для достоверного определения мощностей слоев.

#### *Материалы и методология.*

Георадиолокация, также как и сейсморазведка, является волновым методом [16, с. 3-152], поэтому основные методические приемы, которые используются при геологической интерпретации радарограмм. В сейсморазведке эта методика, получила название сейсмической стратиграфии [17, с. 3-236]. Эта методика основана на анализе динамических и кинематических особенностей всей волновой картины. При интерпретации георадиолокационных данных выделим два основных направления. Первое связано с поиском разнообразных объектов естественного, так и искусственного происхождения. К последним относятся: трубопроводы различного назначения; кабели; коллекторы; карстовые пустоты; археологические объекты и многое другое. Второе направление связано с детальным изучением разреза, о котором в априори ничего не известно.

Анализ волновой картины начинается с выделения осей синфазности отраженных волн, которые являются волнами-помехами.

После обработки и выделения волн-помех радарограммы готовы к интерпретации. Целью интерпретации георадиолокационных данных, является переход от временного разреза к глубинному. Детальное изучение разреза основано на методических приемах, как и в сейсморазведке [17, с. 3-236].

Эта методика разделения разреза применяется и при анализе георадиолокационных данных.

При интерпретации сейсмических данных эта методика получило название сейсмофациального анализа [4, с. 3-284]. Вопрос об определении фации достаточно сложный и неоднозначный [16, с. 3-152; 17, с. 3-236].

Экспериментальные исследования были проведены на песчаном карьере вблизи города Астаны по направлению Кургальджинской трассы. Для проведения эксперимента был использован георадар серии «Люза-В», имеющий диапазон рабочих частот 50-300 МГц, и антенны с разверткой: 0,5 м; 1 м; 1,5 м и 3м. Для исследования выбран метод зондирования, так как в этом случае можно определить мощности слоев неоднородной среды. Данный георадар имеет лицензионное программное обеспечение «Крот-NS» [19].

Первоначальная обработка сырых данных георадара были обработаны по методике профессора А.В. Старовойтова. Нами предложена способ использования этой методики и соответствующих необходимых функций программного обеспечения, что является трудоемкой задачей и требует специализированного подхода и навыков геофизических обработок реальных данных. Проведены экспериментальные исследование на песчаном карьере с использованием георадара «Люза-В». Использован метод зондирования, в котором антенна и источник раздвигаются на равные расстояния от центра

лежащего предполагаемого объекта на карьере. Обработаны по предложенной выше методике два объекта: железная канистра и купол торфа, лежащие в песке на известной глубине. В данном случае это необходимо для тестирования нашей методики исследования. Ниже по шагам приведены все важные этапы обработки сырых реальных данных до конечного результата, а именно переход от временного разреза к геоэлектрическому разрезу.

В данном подразделе определена функциональная зависимость между диэлектрической проницаемостью геофизических свойств неоднородной среды и влажностью этих слоев. С этой целью проведен эксперимент следующего содержания. В заполненную колбу слоями из основных компонент неоднородной среды: фрагменты асфальтового покрытия; щебень различных фракций; балласт и подстилающий слой-грунт, внизу колбы нагнеталась водная струя воды.

Затем с помощью влагомера МГ4 определялась влажность состояний слоев неоднородной среды. Подача воды в колбу фиксировалась с помощью счетчика расходов воды. Были проведены серия измерений, на основе которой экспериментально установлена функциональная зависимость. Эксперименты были проведены с целью определения значения влажности по слоям, при которых происходит расслоение слоев неоднородной среды. В дальнейшем, решая обратную задачу тем или иным способом, определив геоэлектрический разрез, учитывая связь между этими данными и степени влажности можно прогнозировать состояние неоднородности на наличие дефектов.

#### *Подготовка эксперимента*

Для определения зависимости диэлектрических свойств различных слоев дорожной одежды от влажности были проведены экспериментальные исследования в лабораторных условиях на базе Восточно-Казахстанского университета имени Д. Серикбаева. Неоднородная среда состоит из следующих слоев: мелкозернистый асфальт; крупнозернистый асфальт; железобетонная смесь; щебенка фракции 0.4; щебенка фракции 0.8; подстилающий слой -грунт (суглинка). Был создан макет дорожной одежды, с этой целью была взята пластмассовая колба цилиндрической формы с высотой 240 см и диаметром у основания 18 см. Равномерно были помещены в эту колбу последовательно: четвертый слой - грунт, затем слой балласта ; затем слой щебенки и наконец в верхней части колбы разместили слой асфальта мелкозернистого и крупнозернистого.

Между влажностью грунта и его диэлектрической проницаемостью существует прямая и сильная зависимость: с увеличением содержания воды диэлектрическая проницаемость грунта значительно возрастает.

Это объясняется огромной разницей в диэлектрических свойствах компонентов почвы. Например: Чистая вода имеет очень высокую относительную диэлектрическую проницаемость (около 80 при комнатной температуре); Сухой грунт (минеральные частицы и воздух) имеет низкую проницаемость (обычно в диапазоне от 3 до 6, а у воздуха - около 1).

Когда в поры грунта добавляется вода, она замещает воздух, и общая диэлектрическая проницаемость смеси резко увеличивается из-за высокого значения этого параметра у воды.

Ключевые аспекты взаимосвязи:

*Линейность на определенных диапазонах:* В определенных диапазонах влажности и частот электромагнитного поля наблюдается почти линейная зависимость диэлектрической проницаемости от содержания воды.

*Состав и структура грунта:* на эту зависимость также влияют тип почвы (например, содержание глины или гумуса), ее плотность, температура и частота электромагнитного поля.

Согласно эмпирическим исследованиям, проведенным лабораторных условиях, имеющих данные в открытой печати, приведён ряд таблиц о диэлектрической проницаемости и соответственно влажности для ряда интересующих нас материалов (таблица 2).

Таблица 2 – Диэлектрическая проницаемость и скорость

Материал	$\epsilon$	$v$ (см/нс)
Воздух	1	30
Снег	1-2	30-21
Асфальт	3-5	17-13
Лед	4	15
Бетон	4-11	15-9
Породы		
Гранит(сухой)	4-7	15-11
Песчаник(сухой)	6	12
Сланцы	5-15	13-7
Известняки(сухие)	4-8	15-10
Базальты(сухие)	8-9	10
Почвы и отложения	4-30	15-5
Нефть	2,5	19
Вода (пресная и соленая)	81	3,3
Песок плотный		
Сухой	2,93	17
1,5% воды	5	13
3,0% воды	11	9
4,5% воды	39,1	5
Почвы		
7,78% воды	3,95	15
32,1% воды	7,93	10,7
36,8% воды	21,9	6,4
Суглинок сухой	2,44	19,2
Примечание – Составлено по источнику [16, с. 9-12]		

Таблица 3 – Электрические свойства некоторых почв, грунтов и пород в диапазоне радиозондирования по данным лабораторных измерений

Материал	Электрическая проницаемость	Проводимость, см
Сухая песчаная почва	3	$1,5 \cdot 10^{-4}$
Сухой песчаный и глинистый грунт	3-4	-

Влажная песчаная почва	25	7*10-3
Влажный песчаный и глинистый грунт (весовая влажность 4-15%)	4-15	-
Глинистая почва сухая/влажная	3/15	2,5*10-1/5*10-1
Гранит сухой/влажный	5/7	10-5/10-3
Базальт влажный	8	10-2
Глинистый сланец влажный	7	10-1
Песчаник влажный	6	4*10-2
Известняк влажный	8	2,5*10-2
Примечание – Составлено по источнику [16, с. 9-12]		

На рисунке 22, представлены колбы помещенных в ней образцов состава неоднородной среды [16, с. 3-152].



а



б

а – модель подстилающего слоя – грунт; б – модель слоев дорожной одежды: балласт, щебень различной фракции

Рисунок 22 – Колбы с образцами неоднородной среды

### 2. Залив воды в колбу

Для выяснения связи между диэлектрической проницаемостью и влажности состояния слоев дорожной одежды проведен следующий эксперимент. В заполненную колбу со слоями основных пластов дорожной одежды смотрите рисунок 23а. Снизу как указано на рисунке 23б, нагнеталась вода. На соединительном шланге имеется счетчик воды.



а



б

а – модель верхнего слоя дорожной покрытия: образцы асфальтного покрытия; б – подготовленная колба и шланг для нагнетания воды

### Рисунок 23 – Залив воды в колбу

Цель проведения этого эксперимента состоит в следующем. Дорожная одежда автомобильных трасс в процессе эксплуатации на некоторых участках обваливается. Причиной этой служит либо не качественное построение дорог, либо за увлажнения грунта подстилающего слоя, что приводит расслоению слоев дорожной одежды. Поэтому важно определить связь, то есть построить калибровочную функцию зависимости диэлектрической проницаемости и влажности. Таким образом если определить геоэлектрический разрез с помощью георадарных комплексов на основе инженерно-технических методов либо с помощью математического моделирования и имея функцию калибровки можно прогнозировать процесс расслоения пластов дорожной одежды. И задачей экспериментов также состоит в определении пиковой точки расслоения.

Эксперимент проведен докторантом Орман И.М. (рисунок 24а), ниже приведен процесс экспериментальных исследований. С помощью влагомера указанной на рисунке 24б, были проведены измерения влажностей.



а



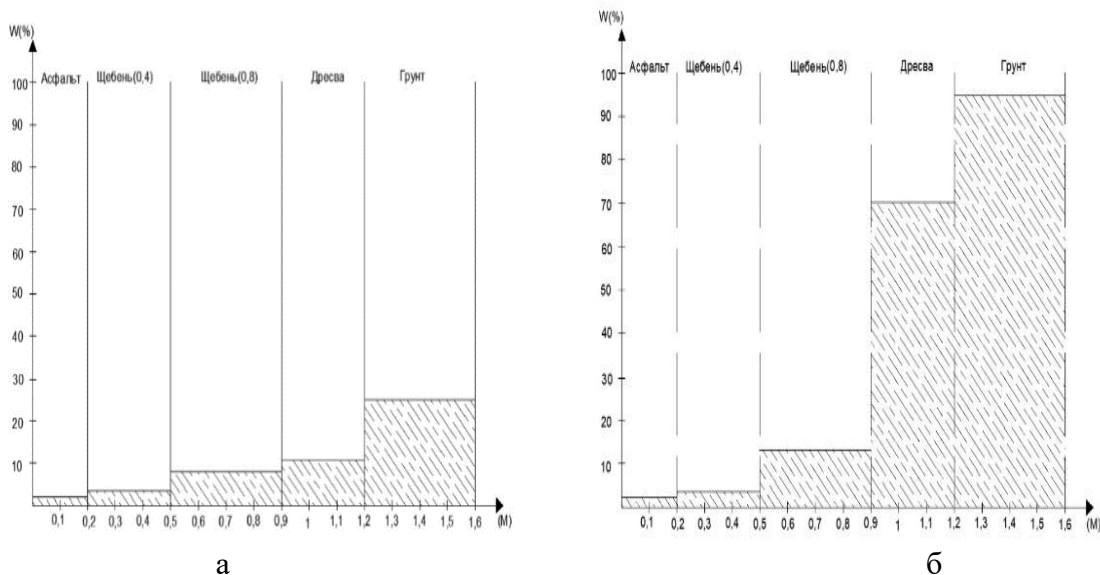
б

а – экспериментатор докторант PhD И.М. Орман; б – Влагомер - МГ4

### Рисунок 23 – Проведение эксперимента

Влагомер - МГ4 – это электронный прибор, который используют для измерения влажности различных материалов: бетона, кирпича, древесины, песка, строительных смесей и других материалов (характеристики приборов).

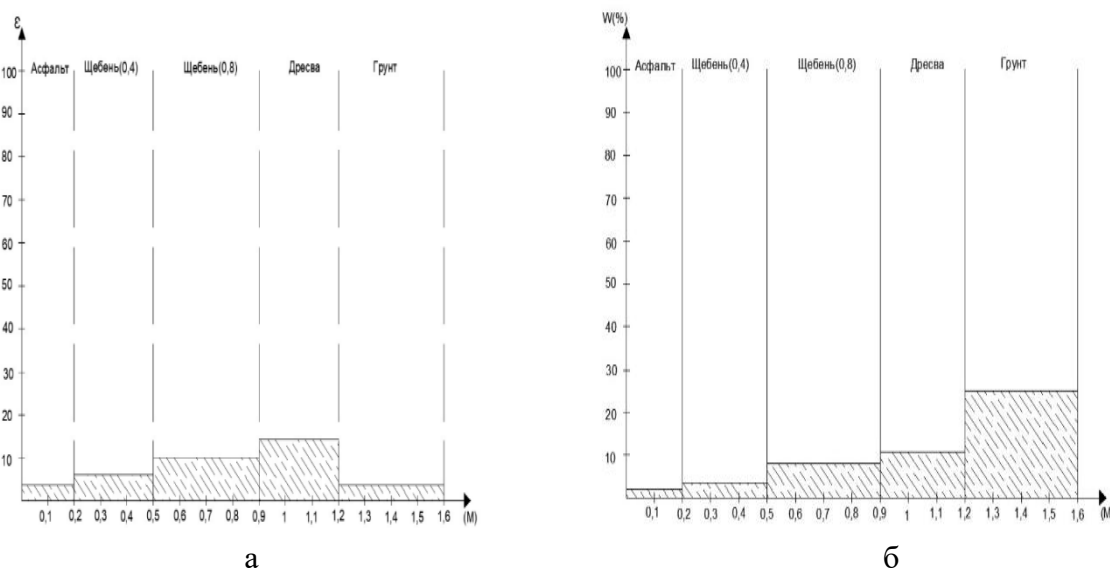
Результаты экспериментальных исследований до забора воды и после указаны на рисунке 24а, 24б в которых отмечены степень влажности слоев грунта до забора воды и после.



а – степень влажности неоднородный среды (до забора воды); б – степень неоднородный среды (после забора воды)

Рисунок 24 – Результаты экспериментальных исследований

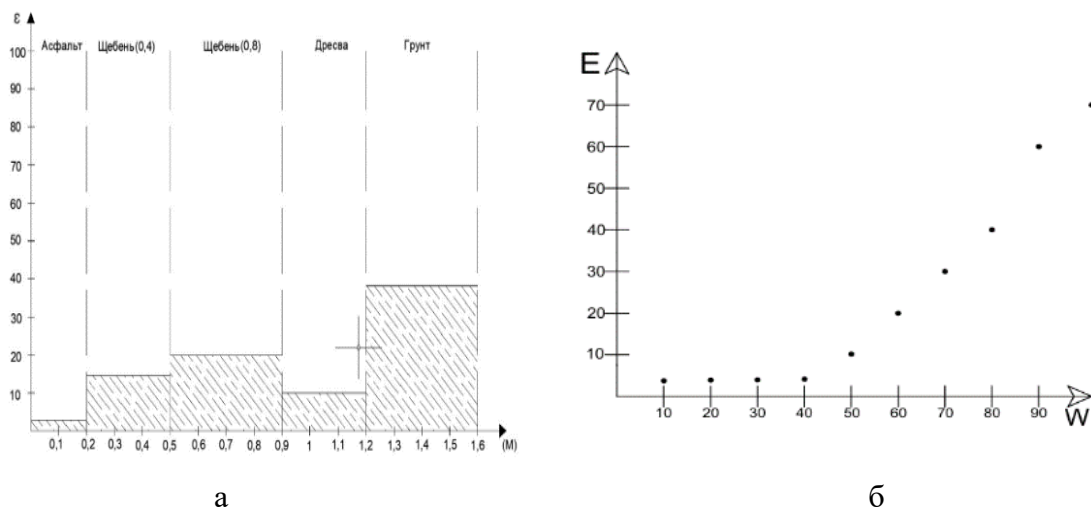
На рисунке 25а, 25б, согласно выше указанных таблиц 1, 2, 3 отмечены значения диэлектрической проницаемости по слоям, причем до забора воды и после.



а – неоднородный среды (после забора воды); б – ε проницаемости до забора воды

Рисунок 25 – Графики диэлектрической проницаемости

И наконец на рисунке 26а, 26б, указана связь между влажностью и диэлектрической проницаемостью по слоям неоднородной среды [13, с. 23-44].



а – связь диэлектрической проницаемости по слоям в глубину; б – экспериментальное установления связи диэлектрической проницаемости и влажности

Рисунок 26 – Связь между влажностью и диэлектрической проницаемостью по слоям неоднородной среды

### Выводы ко второму разделу

Нами проведены экспериментальные исследования с помощью георадара серии «Лоза-В», с целью тестирования методики профессора А.В. Старовойтова для первичной обработки реальных экспериментальных данных георадара. Этот метод в сочетании с программным обеспечением георадарного комплекса, позволяет очистить радарограмму от шумов и различных помех и получить окончательный результат, а именно переход от временного разреза к глубинному. То есть получить геоэлектрический разрез, а именно геоэлектрические свойства неоднородной среды. Антенны георадара фиксируют только время пробега электромагнитного сигнала от неоднородности и является функцией от времени. Глубина проникновения этого сигнала зависит от свойств источника и от антенны. С другой стороны, если сигнал попадает в среду с высокой электромагнитными свойствами, например неоднородный объект, а также с высокой влажностью, то этот объект сам является источником вторичных волн. В связи с этим нами рассмотрен пример с объектом купола торфа, который даже в сухом состоянии обладает высокой диэлектрической проницаемостью. В случае, если подстилающий слой в дорожной одежде имеет высокую влажность, то такой грунт имеет порядок диэлектрической проницаемости порядка 50-80 единиц. В связи с этим проведены нами, во второй части этой статьи экспериментальные исследования по установлению корреляционной зависимости диэлектрической проницаемости и влажности. Последнее позволяет прогнозировать состояние подстилающего грунта.

Разработанная и протестированная методика на основе экспериментальных данных может быть использованы при георадарных исследованиях в различных задачах естествознания, например при прогнозировании дефектов подповерхностных слоёв дорожных конструкций, исследовании строительных участков, а также в задачах археологии.

*Результаты работа данного раздела опубликованы в трудах XVI международная молодежная научная школа-конференция «Теория и численные методы решения обратных и некорректных задач». Институт математики им. С.Л. Соболева СО РАН . 30 сентября–2 октября 2024 года.*

В рамках данного раздела были опубликованы статьи [13, с. 23-44]

Методика интерпретации радарограмм входит в материалы для практических занятия подтверждена акт внедрения в учебный процесс. (Приложение Б)

Результаты расчетов (см. таблицу 4), проведенных выше на реальных данных, подтверждены с данными глубины объектов, в частности, в первом эксперименте с куполом торфа, который находился на глубине порядка 0.8 м, по данным радарограммы, на позиции 0.78 м, во втором примере пластиковые бутылки были закопаны на глубине 0.35 м, были обнаружены на глубине 0.33 м. Таким образом, абсолютная погрешность составила порядка 0,2-0,3 см.

Существующие в настоящее время программные средства обработки георадарных данных не раскрывают использованных методов определения глубины залегания подповерхностных объектов. Математическая модель и программное обеспечение, лежащее в основе обработки данных георадиолокации, являются коммерческой тайной производителей и недоступны для детального анализа.

Наличие собственного программного модуля определения глубины залегания подповерхностных объектов позволяет апробировать алгоритмы, с учетом необходимых свойств подповерхностной среды.

Результаты экспериментальных исследований с применением георадара серии «Лоза-В», методом зондирования дали положительный результат., а именно по определению геоэлектрического разреза.

Имея значения диэлектрической проницаемости по слоям дорожной одежды на основе методики первичной обработки георадарных данных и используя экспериментально установленную зависимость диэлектрической проницаемости, можно спрогнозировать состояние влажности подстилающей среды.

*Результаты этого раздела опубликованы в работе [11, с. 226-232].*

По результату 1 главы опубликована статья в журнале рекомендуемый Комитетом по контролю в сфере образования и науки Министерства образования и науки Республики Казахстан. «Определения глубины залегания включения в подстилающей среде». КРГТУ. Университет Еңбектері - Труды Университета №1, 2024, 519-524стр.

В рамках данного раздела были опубликованы статьи [11, с. 226-232]

Получено авторское свидетельство: Свидетельство о внесении сведений в государственный реестр прав на объекты охраняемые авторским правом №65240 от 11 декабря 2025года. Вид объекта авторского права: Программа для ЭВМ

Название объекта: Программа определения глубины залегания подповерхностных объектов методом георадиолокационного зондирования [15]

### **3 МЕТОДИКА МОНИТОРИНГА И ДИАГНОСТИКИ СТРУКТУРНОГО СОСТОЯНИЯ ПОДПОВЕРХНОСТНЫХ СЛОЁВ НА ОСНОВЕ МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ**

*В данном разделе* рассматривается задача обеспечение долговечных и безопасных подповерхностных слоёв дорожных конструкций имеющих решающее значение для устойчивых транспортных систем и городского развития. Модели, основанные на искусственном интеллекте, позволяют повысить эффективность управления дорожной инфраструктурой за счет прогнозирования её структурного состояния. Это даёт возможность организациям, ответственным за содержание дорог, правильно расставлять приоритеты при проведении ремонтных работ и рационально использовать ресурсы. Интеграция таких моделей с данными сенсоров и транспортных потоков в реальном времени обеспечивает превентивное, экономически эффективное и безопасное управление дорожной сетью. В данном исследовании предложена модель мониторинга структурного состояния подповерхностных слоёв дорожных конструкций, основанная на методах машинного обучения, с целью повышения эффективности обслуживания и управления дорогами. Модель использует такие параметры, как температура асфальта и толщина покрытия, для прогнозирования состояния дорожного полотна. Работоспособность модели была проверена на основе данных полевых испытаний, включая измерения с использованием тяжёлого падающего дефлектометра и георадара. Разработанная модель обеспечивает экономичный и не нарушающий целостность покрытия способ контроля состояния дорожных конструкций и прогнозирования будущих дефектов, что помогает планировать ремонты и оптимизировать использование ресурсов. Интеграция предложенного подхода с системами умного города и умной мобильности позволяет осуществлять мониторинг в реальном времени, повышая безопасность дорожного движения и способствуя созданию устойчивых, эффективных транспортных сетей. Этот подход является ключевым шагом к формированию интеллектуальной и устойчивой городской инфраструктуры. В рамках исследования метод долгой кратковременной памяти был сопоставлен с другими методами машинного обучения. Согласно результатам, модель на основе долгой кратковременной памяти показала наилучшие характеристики как на этапе обучения, так и при тестировании, обеспечив среднеквадратичную ошибку 3,01 и коэффициент корреляции 0,92. Это подтверждает высокую точность прогнозирования и способность модели обобщать новые данные по сравнению с другими подходами. Следовательно, модель на основе долгой кратковременной памяти была выбрана как наиболее эффективный предиктор для использованного в исследовании набора данных. Полученные результаты показывают, что дорожные агентства могут полагаться на системы мониторинга структурного состояния, основанные на искусственном интеллекте, для регулярного контроля состояния подповерхностных слоёв дорожных конструкций. Кроме того, необходимо объединять данные сенсоров и транспортных потоков в централизованных платформах и разрабатывать

политику поддержки прогнозного обслуживания, что позволит продлить срок службы дорог, сократить затраты и повысить безопасность для пользователей.

### **3.1 Описание данных. Методы моделирования**

В данном исследовании были собраны данные для оценки остаточного срока службы (RSL) подповерхностных слоёв дорожных конструкций, который определяется как количество лет, остающихся до момента, когда эксплуатационные характеристики покрытия снизятся ниже допустимого уровня. RSL выступает в качестве зависимой переменной и определяется на основе измерений прогиба поверхности дорожного покрытия, полученных с использованием устройства FWD (Falling Weight Deflectometer – дефлектометр падающего груза). FWD создаёт динамическую нагрузку, имитирующую воздействие транспортных средств, а полученные профили прогиба обрабатываются с использованием процедур обратного расчёта (back-calculation) для оценки структурной несущей способности дорожного покрытия. К основным входным параметрам для определения RSL относятся: толщина асфальтобетонного слоя (AC layer), толщина базового слоя (BS layer), температура поверхности асфальта. Измерения толщины слоёв AC и BS выполняются с использованием георадара (GPR – Ground Penetrating Radar), который является неразрушающим методом, позволяющим определять характеристики подповерхностных слоёв дорожного покрытия. Температура поверхности асфальта фиксируется непосредственно во время полевых обследований, что позволяет учитывать влияние внешних климатических условий при оценке остаточного срока службы покрытия. Собранный набор данных служит основой для разработки моделей, способных оценивать остаточный срок службы дорожного покрытия без использования дорогостоящего оборудования, такого как FWD и GPR, что обеспечивает более экономичный метод оценки состояния покрытия, особенно для регионов с ограниченными ресурсами. Проверка модели проводится с использованием данных, полученных в ходе подробных полевых исследований, включая измерения HWD (Heavy Weight Deflectometer) и GPR, что обеспечивает надёжность и устойчивость прогнозируемых результатов. Разработанная модель представляет собой экономически эффективный и неинвазивный подход к мониторингу структурного состояния подповерхностных слоёв дорожных конструкций (SHM), основанный на применении методов машинного обучения, позволяющих интерпретировать сложные взаимосвязи между входными переменными и реакцией дорожного покрытия.

В данном исследовании моделирование выполнялось с целью прогнозирования мониторинга структурного состояния подповерхностных слоёв дорожных конструкций (SHM). В качестве независимых переменных использовались: температура поверхности асфальтобетонного слоя (AC surface temperature), толщина асфальтобетонного слоя (AC thickness), толщина базового слоя (BS thickness). В то время как остаточный срок службы дорожного покрытия (RSL) выступал в качестве зависимой переменной. В качестве основы сравнительного анализа были использованы семь известных методов машинного

обучения: стохастический градиентный спуск (SGD), Экстремальный Градиентный Бустинг (XGBoost), Искусственная нейронная сеть (ANN), ANN в сочетании с оптимизатором роя частиц (PSO), ANN с интеграцией оптимизатора серого волка (GWO), AdaBoost и LSTM. Моделирование выполнялось с использованием Python 3.6.5 с библиотеками TensorFlow, Scikit-learn и XGBoost на системе Windows 10 (64-бит) с аппаратной конфигурацией 32 Гб оперативной памяти и процессором Intel i7-9750H, а также MATLAB 2018 на той же аппаратной платформе. Для разделения набора данных на обучающую и тестовую выборки использовалось соотношение 75:25, что позволило обеспечить достаточную обучающую способность модели при сохранении объективности оценки. Гиперпараметры оптимизировались методом направленного подбора (trial-and-error) с использованием метрик производительности, включая MAE, RMSE и R<sup>2</sup>, для определения наиболее эффективных конфигураций. В данном исследовании выбор моделей основывался как на данных научной литературы, так и на практическом опыте. Базовые алгоритмы, такие как SGD и ANN, использовались в качестве эталонных моделей, тогда как более продвинутые методы, включая XGBoost, AdaBoost и гибридные модели ANN с оптимизацией PSO и GWO, применялись благодаря их способности выявлять сложные нелинейные зависимости и повышать точность прогнозирования. Модель LSTM была включена в исследование благодаря её способности обрабатывать последовательные данные, что имеет критическое значение для анализа изменения состояния дорожного покрытия во времени. Все вычисления выполнялись в Python и MATLAB на высокопроизводительных системах для обеспечения эффективной обработки данных. Набор данных прошёл тщательную предварительную обработку, включая нормализацию, обработку пропущенных значений и отбор наиболее информативных признаков.

#### *Стохастический градиентный спуск (SGD)*

SGD функционирует как алгоритм оптимизации и также классифицируется как метод машинного обучения [84, p. 104309]. Он определяет оптимальную траекторию обучения моделей машинного обучения, случайным образом выбирая одно наблюдение данных на каждой итерации. Такой подход облегчает вычисление градиентов функции потерь относительно параметров модели. В данном исследовании оптимальная конфигурация была определена с помощью метода проб и ошибок. В результате была получена модель с  $\epsilon$ -интенсивной функцией потерь 0,31, регуляризацией Elastic Net с коэффициентом смешивания 0,15 и скоростью обучения 0,15, что обеспечило наилучшие показатели эффективности (см. таблицу 5).

Таблица 5 – Статистические характеристики переменных

Характеристики переменных	Vx1	Vx 2	Vx 3	Вых
1	2	3	4	5
Среднее значение	27.6180	170.8413	270.7913	18.0521
Объём выборки	576	576	576	576
Стандартное отклонение	4.06419	35.25535	106.38773	15.15706
Медиана	27.7178	166.0000	282.0000	12.0000

Продолжение таблицы 5

1	2	3	4	5
Минимальное значение	19.00	0.00	0.00	0.00
Максимальное значение	35.90	280.00	467.00	40.00
Дисперсия	16.518	1242.940	11318.349	229.736
Козф, асимметрии	-.017	.394	-.062	.463
Примечание – Составлено по источнику [87, р. 213]				

*Метод экстремального градиентного бустинга (XGBoost)*

XGBoost представляет собой ансамблевый метод машинного обучения, который формирует устойчивую прогностическую модель путём объединения нескольких деревьев решений [85, р. e05116]. Процесс начинается с начальной оценки, обычно равной среднему значению целевой переменной, после чего прогнозы последовательно уточняются за счёт обучения последующих моделей на остатках предыдущих итераций. Такой подход позволяет XGBoost акцентировать внимание на ранее неправильно классифицированных наблюдениях и снижать смещение, что повышает общую точность прогнозирования. В данном исследовании гиперпараметры были настроены методом проб и ошибок, при этом число деревьев было установлено равным 25, скорость обучения – 0,3, а параметр регуляризации  $\lambda$  – 0,8, что обеспечило оптимальные результаты прогнозирования (см. таблицу 5).

*Искусственная нейронная сеть (ANN)*

ANN является методом машинного обучения, вдохновлённым структурой человеческой нервной системы [60, р. 4-14]. Он предназначен для имитации процессов обучения и обработки информации человеком. Сеть состоит из взаимосвязанных узлов – «нейронов», организованных в слои. Обычно архитектура ANN включает три типа слоёв: входной слой, принимающий данные из внешней среды; один или несколько скрытых слоёв, обрабатывающих информацию с использованием взвешенных связей и функций активации; и выходной слой, формирующий окончательные прогнозы. В данном исследовании архитектура ANN была определена методом проб и ошибок, в результате чего была получена конфигурация 3-18-4-1 с функцией активации ReLU и решателем SGD, что обеспечило наиболее точные прогнозы (см. таблицу 5).

Искусственная нейронная сеть (ANN), интегрированная с алгоритмом оптимизации роя частиц (PSO)

На данном этапе ранее разработанная архитектура ANN была объединена с алгоритмом оптимизации роя частиц (PSO) для более эффективной оптимизации весов и смещений. Такой подход улучшает процесс обучения за счёт динамической настройки параметров сети. PSO представляет собой популяционный алгоритм оптимизации, в котором каждая частица рассматривается как кандидатное решение и обновляет своё положение в пространстве поиска, учитывая как собственный опыт, так и опыт соседних частиц. Этот механизм напрямую влияет на производительность нейронной сети ANN. В рамках процедуры подбора методом проб и ошибок существующая

архитектура сети была повторно обучена с использованием PSO с 150 частицами и максимальным числом итераций 680, что позволило получить оптимизированную конфигурацию модели (см. таблицу 5).

Искусственная нейронная сеть (ANN), интегрированная с алгоритмом оптимизации серых волков (GWO)

На данном этапе разработанная ранее ANN была интегрирована с алгоритмом оптимизации серых волков (Grey Wolf Optimizer – GWO) для повышения эффективности оптимизации весов и смещений сети. Использование дополнительного оптимизационного алгоритма в процессе обучения ANN позволяет улучшить настройку параметров, что приводит к повышению точности прогнозирования. GWO является алгоритмом роевого интеллекта, имитирующим социальное охотничье поведение серых волков, основанное на иерархическом лидерстве и кооперативных стратегиях поиска решений [86, р. 69-88]. Параметры данного метода были определены методом проб и ошибок, при этом использовалось 100 «волков» и 510 итераций, что позволило получить оптимальную конфигурацию модели (см. таблицу 5).

*Метод адаптивного бустинга (AdaBoost)*

AdaBoost является методом ансамблевого машинного обучения, который объединяет несколько слабых классификаторов для формирования мощной прогностической модели [87, р. 213]. На начальном этапе алгоритм присваивает одинаковые веса всем обучающим примерам, после чего они итеративно корректируются после обучения каждой модели. Этот процесс продолжается до достижения заданного количества классификаторов. Итоговый прогноз формируется как взвешенная сумма всех слабых моделей, причём модели с более высокой точностью оказывают большее влияние на конечный результат. В данном исследовании конфигурация AdaBoost была определена с использованием метода проб и ошибок (см. таблицу 5).

*Модель на основе долгой кратковременной памяти (LSTM)*

LSTM (Long Short-Term Memory) является специализированной разновидностью рекуррентных нейронных сетей (RNN) и относится к классу методов глубокого обучения (DL). Данная архитектура регулирует поток информации, позволяя сохранять важные закономерности на протяжении длинных последовательностей данных, одновременно отбрасывая нерелевантную информацию в процессе обучения [25, с. 272-285; 88, р. 5211-5225]. Конфигурация сети была определена методом проб и ошибок. Оптимизированная модель LSTM включала: два скрытых слоя, по 50 нейронов в каждом слое, скорость обучения (learning rate) – 0,0008 (см. таблицу 5).

### **3.2 Статистические характеристики набора данных. Результаты моделирования**

На данном этапе анализируются взаимосвязи между переменными. В таблице 5 представлены статистические характеристики переменных, включая: среднее значение (mean), размер выборки (sample size), стандартное отклонение (standard deviation), медиану (median), минимальное значение (minimum),

максимальное значение (maximum), дисперсию (variance), коэффициент асимметрии (skewness).

В таблице 6 представлены результаты дисперсионного анализа (ANOVA) для исследуемых переменных. Анализ показывает, что влияние входных переменных на выходную переменную является статистически значимым на уровне значимости 5%, что подтверждает возможность надёжного проведения процесса моделирования.

Таблица 6 – Результаты ANOVA

Наименование		Сумма кв.	ст. своб.	Ср. кв.	F	Знач.
Вх 1 * Межгрупп.	(объедин.)	860.61	39	22	1.38	.046
Вых Внутригрупп		8772.044	8572.04	536	16	-
Total	-	9497.656	-	575	-	-
Вх 2 * Межгрупп.	(объедин.)	70273.5	39	1802	1.49	.029
Вых Внутригрупп		644416.757	644416.75	536	1202	-
Total	-	714690.257	-	575	-	-
Вх 3 * Межгрупп.	(объедин.)	563803.97	39	14457	1.35	.048
Вых Внутригрупп		5971966.579	5719696.7	563	10671	-
Итого	-	6508050.557	-	575	-	-
Примечание – Составлено по источнику [87, р. 213]						

Данный этап включает две фазы: обучение (training) и тестирование (testing).

Таблица 7 – Результаты обучения разработанных моделей

Модель	Архитектура	RMSE	CC
SGD	Функция потерь $\epsilon$ -интенсивного типа со значением 0,31, регуляризация Elastic Net с коэффициентом смешивания 0,15 и скорость обучения 0,15.	6.92	0.73
XGboost	Число деревьев 25, скорость обучения 0,3, параметр $\lambda = 0,8$	17.04	0.88
ANN-PSO	Архитектура 3-18-4-1 с оптимизацией PSO (150 частиц, 680 итераций)	2.96	0.96
ANN	Архитектура 3-18-4-1, функция активации ReLU, оптимизатор SGD	3.46	0.94
ANN-GWO	Архитектура 3-18-4-1 с оптимизацией GWO (100 волков, 510 итераций)	2.82	0.97
AdaBoost	Число оценщиков 12, скорость обучения 0,3, квадратичная функция потерь	5.34	0.88
LSTM	Два скрытых слоя по 50 нейронов, скорость обучения 0,0008	2.45	0.98
Примечание – Составлено по источнику [87, р. 213]			

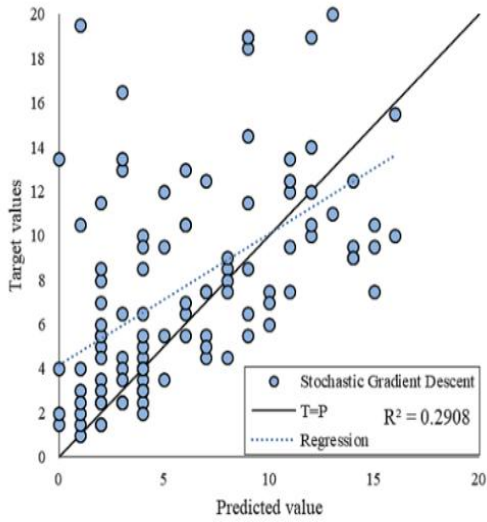
В таблице 7 представлены результаты обучения моделей. Модель LSTM показала наилучшую производительность, продемонстрировав: минимальное значение RMSE – 2,45, наивысшее значение коэффициента корреляции (CC) – 0,98. Это свидетельствует о очень высокой точности прогнозирования и сильном соответствии с наблюдаемыми данными. Модель ANN-GWO также показала

высокую эффективность: RMSE – 2,82, CC – 0,97, что примерно на 15% менее точно, чем результаты модели LSTM. Следующие позиции заняли модели ANN-PSO и ANN, которые достигли: RMSE – 2,96 и 3,46, CC – 0,96 и 0,94 соответственно. В отличие от них, модель XGBoost, несмотря на достаточно высокий коэффициент корреляции 0,88, продемонстрировала значительно более высокое значение RMSE (17,04), что указывает на более низкую точность прогнозирования. Метод SGD показал наихудшие результаты, с: RMSE – 6,92, CC – 0,73, что делает его неподходящим для решения данной задачи. На основании результатов обучения можно рекомендовать модели LSTM и ANN-GWO для задач высокоточного прогнозирования, однако для окончательного вывода необходимо также учитывать результаты тестовой фазы.


Таблица 8 – Результаты тестирования разработанных моделей

Модель	Архитектура	RMSE	CC
SGD	Функция потерь $\epsilon$ -интенсивного типа со значением 0,31, регуляризация Elastic Net с	9.47	0.53
XGboost	коэффициентом смешивания 0,15 и скорость обучения 0,15. Число деревьев 25, скорость обучения 0,3, параметр $\lambda = 0,8$	20.16	0.62
ANN-PSO	Архитектура 3-18-4-1 с оптимизацией PSO (150 частиц, 680 итераций)	3.75	0.85
ANN	Архитектура 3-18-4-1, функция активации ReLU, оптимизатор SGD	4.92	0.81
ANN-GWO	Архитектура 3-18-4-1 с оптимизацией GWO (100 волков, 510 итераций)	3.55	0.89
AdaBoost	Число оценщиков 12, скорость обучения 0,3, квадратичная функция потерь	14.44	0.72
LSTM	Два скрытых слоя по 50 нейронов, скорость обучения 0,0008	3.01	0.92
Примечание – Составлено по источнику [87, p. 213]			

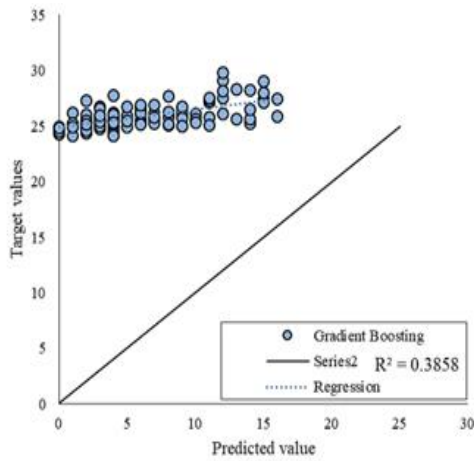
В таблице 8 представлены результаты тестирования моделей. Сравнение этих результатов с фазой обучения показывает, что модель LSTM продемонстрировала наивысшую эффективность на обеих стадиях. В тестовой фазе модель LSTM показала: RMSE – 3,01, CC – 0,92, что свидетельствует о высокой точности прогнозирования и хорошей способности модели к обобщению при работе с ранее не встречавшимися данными. По сравнению с этапом обучения наблюдается некоторое снижение точности. Для модели LSTM снижение производительности составило примерно 20%. Модель ANN-GWO также продемонстрировала хорошие результаты: RMSE – 3,55, CC – 0,89, однако её эффективность снизилась примерно на 40% по сравнению с фазой обучения. Другие модели показали снижение точности более чем на 40%, что указывает на их меньшую надёжность. Примечательно, что модели SGD и XGBoost продемонстрировали сравнительно слабые результаты на этапе тестирования, что может свидетельствовать о переобучении (overfitting). Полученные результаты подтверждают высокий уровень доверия и способность к обобщению модели LSTM, в связи с чем она рекомендуется в качестве оптимального решения для данного анализа.



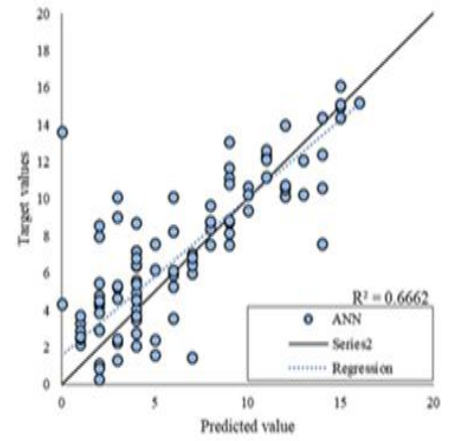
а




б




в



г



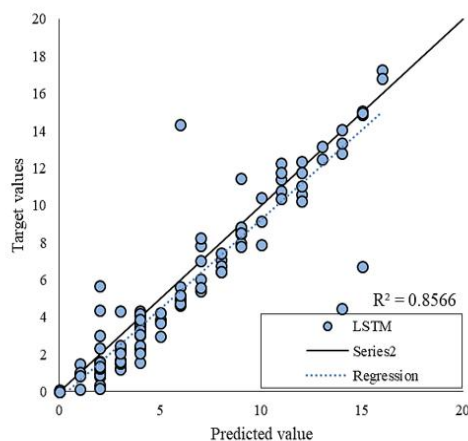
д



е

а – стохастический градиентный спуск (SGD); б – градиентный бустинг; в – искусственная нейронная сеть с оптимизацией частиц (ANN-PSO); г – искусственная нейронная сеть (ANN); д – искусственная нейронная сеть с оптимизацией серого волка (ANN-GWO); е – адаптивный бустинг (AdaBoost)

Рисунок 35 – Диаграммы результатов тестовой фазы, лист 1



Ж

ж – долгая краткосрочная память (LSTM)

Рисунок 35, лист 2

Примечание – Составлено по источнику [87, р. 213]

На рисунке 35 представлены графические диаграммы разработанных моделей на этапе тестирования. Как видно из рисунка, линии регрессии для моделей SGD, XGBoost и AdaBoost значительно отклоняются от линии 1:1, что указывает на слабое соответствие между прогнозируемыми и фактическими значениями, а следовательно, на низкую надёжность их прогнозов. В отличие от них, модели, основанные на искусственных нейронных сетях (ANN) и глубоком обучении (DL), демонстрируют линии регрессии, близкие к линии 1:1, что подтверждает высокую степень соответствия и надёжность результатов. Диаграмма рассеяния (scatter plot) иллюстрирует взаимосвязь между прогнозируемыми и фактическими значениями для модели LSTM. Каждая точка на графике представляет прогнозируемое значение, сопоставленное с соответствующим наблюдаемым значением. Сплошная линия обозначает идеальное соотношение 1:1, при котором прогнозы полностью совпадают с наблюдаемыми значениями. Пунктирная линия представляет регрессионную зависимость между прогнозируемыми и фактическими значениями. Высокое значение коэффициента детерминации ( $R^2 = 0,8566$ ) указывает на то, что модель объясняет значительную долю вариации целевых значений, что свидетельствует о высокой прогностической

Диаграмма рассеяния показывает взаимосвязь между прогнозируемыми и целевыми (наблюдаемыми) значениями для модели LSTM (долгой кратковременной памяти). Каждая точка на графике представляет собой предсказанное значение, нанесённое против соответствующего наблюдаемого значения. Сплошная линия отражает идеальное соотношение 1:1, при котором прогноз полностью совпадает с наблюдением, в то время как пунктирная линия показывает регрессионную зависимость между предсказанными и фактическими значениями. Высокий коэффициент детерминации ( $R^2=0.8566$ ) указывает на то, что модель объясняет значительную долю дисперсии целевых значений, что свидетельствует о хороших прогностических способностях модели, хотя небольшие

отклонения указывают на случаи пере- или недооценки результатов. Рисунок 36 демонстрирует относительную квадратичную ошибку (RelativeSquareError, RSE) тестовой фазы для каждой модели. Согласно рисунку, XGBoost имеет наибольшую отрицательную относительную ошибку, в то время как LSTM демонстрирует наименьшую положительную относительную ошибку. Желательное значение ошибки в данном анализе должно быть положительным и минимальным, так как отрицательная ошибка указывает на обратную корреляцию между предсказанными и фактическими значениями, что не соответствует целям данного исследования считается некорректным результатом.

На рисунке 36 представлены значения относительной квадратичной ошибки для каждой модели на этапе тестирования. Как видно из результатов, модель XGBoost демонстрирует наибольшую отрицательную относительную ошибку, тогда как модель LSTM достигает наименьшей положительной относительной ошибки. В данном контексте наиболее предпочтительной считается минимальная положительная ошибка. Отрицательные значения ошибки указывают на обратную зависимость между прогнозируемыми и фактическими значениями, что противоречит задачам данного исследования. Кроме того, анализ показателя MAE (средняя абсолютная ошибка) для всех моделей показывает, что модель LSTM имеет наименьшее значение ошибки, что свидетельствует о наивысшей точности прогнозирования и надёжности модели. Модели на основе искусственных нейронных сетей, включая ANN-GWO и ANN-PSO, также демонстрируют относительно низкие значения ошибок.

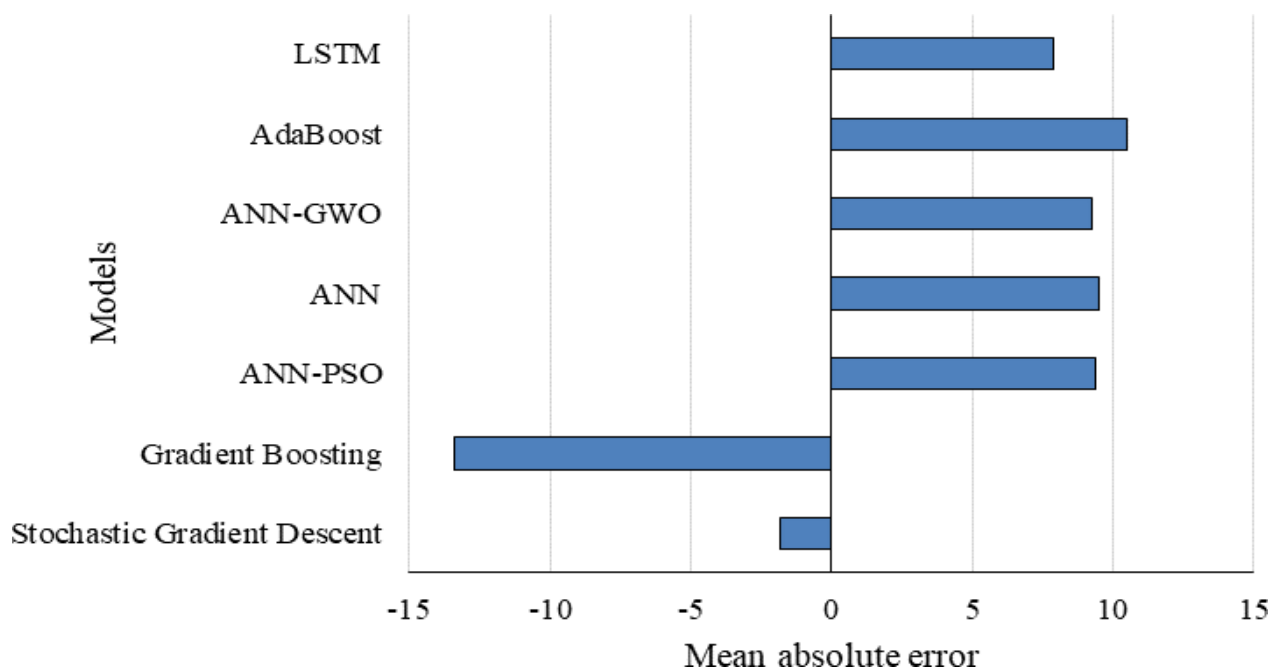


Рисунок 36 – Квадратичная относительная погрешность этапа тестирования

Примечание – Составлено по источнику [87, p. 213]

В противоположность этому модели Gradient Boosting и SGD показали

наиболее слабые результаты, что указывает на их ограниченную пригодность для задач прогнозирования состояния подповерхностных слоёв дорожных конструкций.

При рассмотрении средней абсолютной ошибки (MAE) для различных моделей можно отметить, что LSTM имеет наименьшую ошибку среди всех моделей, что свидетельствует о наибольшей точности и надёжности прогнозирования. Модели на основе искусственных нейронных сетей (ANN), включая ANN-GWO и ANN-PSO, также показали относительно низкие значения ошибок, в то время как методы градиентного бустинга (GradientBoosting) и стохастического градиентного спуска (SGD) продемонстрировали худшие результаты, что указывает на их низкую применимость для задач прогнозирования состояния дорожного покрытия данного типа.

Результаты данного исследования демонстрируют превосходство модели LSTM при прогнозировании мониторинга структурного состояния подповерхностных слоёв дорожных конструкций (SHM). При значениях  $RMSE=3,01$  и  $CC=0,92$  модель LSTM превзошла все другие рассмотренные модели, показав высокую точность прогнозирования и устойчивую способность к обобщению при работе с ранее не встречавшимися данными. Визуальный анализ в представленный на рисунках 35 и 36, дополнительно подтверждает способность модели LSTM выявлять сложные временные зависимости в наборе данных. Последовательная архитектура LSTM особенно хорошо подходит для анализа временных данных, что имеет ключевое значение при мониторинге инфраструктуры, где состояние дорожного покрытия изменяется с течением времени. Среди моделей на основе искусственных нейронных сетей гибридная модель ANN-GWO также продемонстрировала высокую эффективность, достигнув  $RMSE = 3,55$  и  $CC = 0,89$ , что указывает на то, что нейронные сети с оптимизационными алгоритмами способны обеспечивать достаточно точные прогнозы. Однако различие между результатами ANN-GWO и LSTM подчёркивает ограничения традиционных моделей ANN в представлении долгосрочных зависимостей и нелинейных процессов деградации. Полученные результаты согласуются с предыдущими исследованиями, в которых показано, что методы глубокого обучения (DL) превосходят традиционные модели при прогнозировании временных рядов и мониторинге структурного состояния инфраструктуры.

Другие модели, включая ANN-PSO и стандартную ANN, показали средний уровень эффективности, тогда как XGBoost и SGD оказались менее результативными. Несмотря на устойчивость XGBoost при работе со структурированными данными, этот метод не способен эффективно моделировать временные зависимости, тогда как относительно слабые результаты SGD объясняются его чувствительностью к распределению данных и ограниченной способностью выявлять нелинейные взаимосвязи без значительной настройки параметров или инженерии признаков. В совокупности полученные результаты показывают, что выбор модели не должен основываться исключительно на точности прогнозирования. Не менее важными являются способность модели к обобщению в реальных условиях эксплуатации и точное

отражение поведения исследуемой системы. Модель LSTM удовлетворяет обоим этим требованиям, что делает её перспективным инструментом для практического мониторинга подповерхностных слоёв дорожных конструкций. Обучаясь на исторических данных и прогнозируя будущие процессы деградации, LSTM позволяет реализовать проактивное техническое обслуживание и долгосрочное планирование инфраструктуры. Эти результаты подтверждают современные исследования, в которых рекомендуется использование глубокого обучения в управлении транспортной инфраструктурой, а также указывают на перспективные направления дальнейших исследований, включая: разработку ансамблевых и гибридных методов обучения, интеграцию данных о дорожных покрытиях и транспортных потоках в единые модели, применение объяснимого искусственного интеллекта (Explainable AI) для повышения интерпретируемости моделей. Интеграция передовых моделей, таких как LSTM, в системы операционного мониторинга позволит транспортным организациям перейти к более эффективному и устойчивому управлению инфраструктурой.

В данном исследовании анализируется надёжность методов глубокого обучения (DL) для моделирования мониторинга структурного состояния подповерхностных слоёв дорожных конструкций (SHM), используя температуру асфальта и толщину слоёв дорожного покрытия для прогнозирования текущего состояния и будущих процессов деградации. Эффективность моделей была подтверждена полевыми измерениями, полученными с использованием HWD и GPR, что подтвердило точность и устойчивость прогнозируемых результатов. Среди всех рассмотренных моделей LSTM продемонстрировала наилучшую эффективность, за ней следовала ANN-GWO. Другие методы, включая ANN-PSO, ANN, XGBoost и SGD, показали более низкую надёжность и считаются менее подходящими для данного типа задач. Высокоэффективные модели могут быть интегрированы с системами умного города (Smart City) и Интернета вещей (IoT) для обеспечения мониторинга подповерхностных слоёв дорожных конструкций в режиме реального времени, который будет: экономически эффективным, неразрушающим, непрерывным. Такая интеграция способствует: повышению безопасности дорожного движения, снижению расходов на техническое обслуживание, увеличению срока службы подповерхностных слоёв дорожных конструкций. Транспортным организациям рекомендуется внедрять системы мониторинга на основе искусственного интеллекта, а также объединять данные датчиков, транспортных потоков и экологических факторов для поддержки обоснованного принятия решений. Необходимы также политические и управленческие меры, направленные на развитие прогностических стратегий технического обслуживания, что позволит оптимизировать бюджеты и одновременно повысить общественную безопасность и устойчивость инфраструктуры. Будущие исследования должны: изучить дополнительные модели машинного обучения, использовать более крупные и разнообразные наборы данных, проверить эффективность моделей в различных регионах. Дальнейшие исследования также должны сосредоточиться на: объяснимом искусственном интеллекте (Explainable AI), гибридных и ансамблевых методах

обучения, методах переноса обучения (transfer learning). Кроме того, объединение прогнозирования транспортных потоков с мониторингом подповерхностных слоёв дорожных конструкций посредством пространственно-временного моделирования позволит создать единые системы управления городской мобильностью и инфраструктурой, способствующие формированию устойчивых и устойчивых к изменениям городов.

### **Выводы к третьему разделу**

Результаты данного исследования ясно демонстрируют превосходство модели LSTM (долгой кратковременной памяти) в прогнозировании структурного состояния подповерхностных слоёв дорожных конструкций. При  $RMSE = 3.01$  и коэффициенте корреляции ( $CC$ ) = 0.92 модель LSTM превзошла все остальные протестированные модели, показав высокую точность прогнозирования и сильную способность к обобщению на новые данные. Эти результаты, подтверждённые визуальными анализами на рисунках 35 и 36, указывают на способность модели LSTM улавливать сложные временные зависимости в наборе данных. Архитектура LSTM особенно хорошо подходит для последовательных и временных данных, что критически важно для задач мониторинга инфраструктуры, где состояние покрытия изменяется с течением времени. Для сравнения, модели на основе ANN, особенно гибридная ANN-GWO, также показали обнадеживающие результаты. Модель ANN-GWO достигла  $RMSE = 3.55$  и  $CC = 0.89$ , что демонстрирует эффективность нейронных сетей, интегрированных с алгоритмами оптимизации, в прогнозировании подобных процессов. Однако разница в производительности между ANN-GWO и LSTM указывает на то, что традиционные ANN-модели могут иметь ограниченные возможности при обучении долговременным зависимостям или моделировании нелинейных процессов деградации. Это наблюдение согласуется с предыдущими исследованиями, подтверждающими преимущества методов глубокого обучения для задач временных рядов и мониторинга структурного состояния. Другие модели, такие как ANN-PSO и стандартная ANN, продемонстрировали средний уровень эффективности, в то время как XGBoost и SGD оказались менее результативными в данном контексте. Это, вероятно, связано с тем, что указанные методы не предназначены для анализа временных зависимостей. Например, XGBoost хорошо работает со структурированными данными, но не имеет внутренней памяти, необходимой для моделирования динамических, зависящих от времени процессов. А сравнительно слабая производительность SGD объясняется его чувствительностью к распределению данных и ограниченной способностью моделировать нелинейности без сложной настройки гиперпараметров или инжиниринга признаков. В совокупности эти результаты подчёркивают, что точность прогнозирования не должна быть единственным критерием при выборе модели.

Не менее важно учитывать, насколько хорошо модель способна обобщать результаты на реальные условия и отражать внутреннюю динамику изучаемой системы. Модель LSTM, удовлетворяя обоим критериям, представляет собой оптимальный вариант для практического применения в мониторинге

подповерхностных слоёв дорожных конструкций. Её способность обучаться на исторических данных и предсказывать будущую деградацию делает её особенно ценной для прогнозного обслуживания и долгосрочного планирования инфраструктуры. Эти выводы согласуются с современными исследованиями, в которых подчеркивается важность глубокого обучения в управлении транспортными активами. Кроме того, результаты данного исследования указывают на перспективные направления дальнейших работ, включая: разработку ансамблевых и гибридных методов обучения, интеграцию данных о дорожных покрытиях и трафике в единые модели, применение объяснимого искусственного интеллекта (ExplainableAI) для повышения интерпретируемости моделей. Внедрение таких продвинутых моделей, как LSTM, в операционные системы мониторинга позволит транспортным агентствам сделать значительный шаг к умному, эффективному и устойчивому управлению инфраструктурой.

Настоящее исследование демонстрирует, что глубокое обучение (DeepLearning) может служить надёжным инструментом для моделирования мониторинга структурного состояния подповерхностных слоёв дорожных конструкций. Учитывая ключевые факторы, такие как температура асфальта и толщина покрытия, предложенная модель смогла с высокой точностью предсказать состояние дорожного покрытия и его последующую деградацию, что было подтверждено полевой валидацией с использованием данных HWD (HeavyWeightDeflectometer - тяжёлого падающего дефлектометра) и GPR (GroundPenetratingRadar - георадара). По сравнению с традиционными методами и другими подходами машинного обучения, модель глубокого обучения показала себя как более эффективная и надёжная, способная работать со сложными наборами данных и поддерживать проактивное техническое обслуживание и долгосрочное управление дорожной инфраструктурой. Среди протестированных моделей модель LSTM (LongShort-TermMemory) показала наилучшую производительность и наивысший коэффициент корреляции, за ней следует модель ANN-GWO (искусственная нейронная сеть с оптимизацией серого волка), которая была несколько менее точной, но всё же высокоэффективной.

Модели ANN-PSO и ANN показали умеренные результаты, тогда как XGBoost и особенно SGD проявили себя слабо, при этом SGD оказался непригодным для данного типа задач. На основании этих результатов модели LSTM и ANN-GWO рекомендуется использовать на практике. Интеграция таких моделей в системы умных городов (SmartCity) позволит реализовать оперативный, экономичный и ненавязчивый мониторинг подповерхностных слоёв дорожных конструкций, что поможет транспортным ведомствам повысить безопасность дорожного движения, сократить расходы на обслуживание и продлить срок службы дорог. С практической точки зрения транспортным агентствам следует рассмотреть внедрение систем мониторинга, основанных на искусственном интеллекте, а также интеграцию данных от сенсоров, трафика и факторов окружающей среды в единые аналитические платформы для повышения качества управленческих решений. На уровне политики необходимы поддерживающие нормативные и организационные рамки, способствующие

развитию предиктивных стратегий технического обслуживания, которые позволят эффективнее использовать ограниченные бюджеты, одновременно повышая общественную безопасность и устойчивость инфраструктуры. Одним из ограничений данного исследования является то, что оно рассматривает лишь определённый набор методов машинного обучения, что означает, что некоторые потенциально полезные подходы могли быть упущены. В дальнейшем исследовании следует тестировать более широкий спектр моделей и использовать более крупные и разнообразные наборы данных, включающие различные типы покрытий, дорог и климатических условий. Также важно проверить модели в разных регионах, чтобы определить, насколько хорошо они работают в реальных эксплуатационных условиях. Кроме того, будущие исследования должны быть направлены на усовершенствование автоматического выявления дефектов подповерхностных слоёв дорожных конструкций с применением объяснимого искусственного интеллекта (ExplainableAI) для повышения прозрачности и доверия к результатам, а также на тестирование гибридных, ансамблевых и методов переноса обучения (TransferLearning), которые могут повысить точность в условиях различных климатов и распределений данных. Комбинирование прогнозирования

транспортных потоков с мониторингом подповерхностных слоёв дорожных конструкций посредством пространственно-временного моделирования (spatiotemporal modeling) может привести к созданию унифицированных систем управления городской мобильностью и инфраструктурой, способствуя реализации концепции умных, устойчивых и устойчивых к изменениям городов.

В рамках данного раздела была опубликована статья в базе Scopus Mohamadreza Azodinia, Kazizat Iskakov, Orman Indira, Sina Ardabili, Nader Karballaezadeh, Amir Mosavi. Deep Learning for Structural Health Monitoring of Pavements for Improving Road Maintenance and Management. Vol. 8 No. 2 (2025): Decision Making: Applications in Management and Engineering [9, p7 863-879].

## **4 РАЗРАБОТКА МЕТОДА ОПРЕДЕЛЕНИЯ ПАРАМЕТРОВ ИСТОЧНИКА И ПОДСТИЛАЮЩЕГО СЛОЯ**

В данном разделе описан процесс калибровки источника зондирования георадара. Приведено математическое обоснование этого процесса, результаты калибровки по данным, измеренным на песочном карьере, где электромагнитные параметры зондирующей среды являются известными. Полученные значения параметров, характеризующие поведение источника, теперь могут считаться известными и использоваться для численного решения обратных задач по определению неизвестных электромагнитных параметров среды с использованием алгоритмов, которые не являются встроенными в математическое обеспечение георадара.

На примере экспериментальных исследований, проведенных с помощью георадара «Лоза-В», изложена методика первичной обработки экспериментальных данных георадара. Все измерения проводились методом зондирования. Выбран участок песчаного карьера, однородной среды – речной песок. На этом участке (песчаный карьер), находящийся вблизи города Астаны, исследованы различные объекты. Проведена интерпретация серии радарограмм, полученных в результате экспериментальных исследований с георадаром на основе метода зондирования. Результаты этих исследований необходимы для решения коэффициентных обратных задач, а именно по определению геофизических свойств подстилающего слоя.

Далее в данном разделе представлен численный алгоритм определения электрических параметров подстилающего слоя неоднородной среды.

На практике такого сорта задача возникает, например во время эксплуатации дорожного покрытия из-за природных условий может происходить деформирование, поднятия грунтовых вод, техногенных явлений, нарушения целостности грунта, потеря его однородности, содержания в грунте крупного инородного объекта, и т.д. Задача определения горизонтальной компоненты электрической напряженности на некоторой глубине упрощается в тех случаях, когда электромагнитные свойства первых нескольких слоев известны, а свойства подстилающей среды подлежат определению. Нами представлен численный алгоритм определения диэлектрической проницаемости грунта-подстилающего слоя. В такой постановке отпадает необходимость решения обратной задачи оптимизационным методом.

### **4.1 Математическое моделирование уточнения формы источника**

Источник был откалиброван на среде с известными электромагнитными параметрами. Нами рассматривается возможность определения зондирующего источника георадара.

С математической точки зрения задача эквивалентна решению обратной задачи определения правой части дифференциального уравнения. Как правило, встроенное программное обеспечение георадара использует алгоритмы интерпретации, основанные на временах пробега электромагнитных волн. В этом случае точная форма функции, описывающей источник во времени, не

требуется [60, р. 4-14; 91, р. 4622-4636]. Однако при использовании других алгоритмов для восстановления электромагнитных свойств среды (например, [92, р. 84-90]) знание функции источника с высокой точностью становится необходимым. Более того, в процессе эксплуатации георадар может подвергаться механическим повреждениям, что также приводит к изменению его источниковой функции.

Для определения функции источника рассмотрим решения прямой задачи в частотной области. Основная сложность заключается в том, что георадар зондирует среду лишь на нескольких фиксированных частотах, поэтому функция источника может быть восстановлена только в ограниченном диапазоне частот. В то же время общая форма поведения функции источника заранее известна, что позволяет свести задачу к определению лишь нескольких параметров, от которых она зависит. Решение соответствующего дифференциального уравнения в частотной области представлено в аналитической форме, а обратная задача восстановления источника сводится к поиску минимума функционала.

Рассмотрим модель среды, в которой электромагнитные параметры зависят только от глубины  $z$ : область  $\{z < 0\}$  соответствует воздуху, а область  $\{z > 0\}$  - среде.

Пусть электромагнитное поле возбуждается источником вида:

$$j(r, \varphi, t) = (j_r, j_\varphi, j_z)^T = (0, j_\varphi, 0)^T, \quad j_\varphi(r, \varphi, t) = f(t)g(r)\delta(z - z_*). \quad (10)$$

где  $z_*$  - координата источника на оси  $Oz$ ,  $z_* < 0$  значение  $z_*$  достаточно мало, а функция  $g(r) = \theta(r_0 - r)$ , где  $r_0 > 0$  параметр источника,  $\theta(x)$  - функция Хэвисайда.

Для компоненты  $E_\varphi$  можно получить следующее уравнение (см., например, [93, р. 610-623]):

$$\mu\epsilon_0\epsilon E_{\varphi,tt} + \mu\sigma E_{\varphi,t} = E_{\varphi,zz} + ((1/r)(rE_\varphi)_r)_r - \mu j_{\varphi,t}, \quad (11)$$

для которого выполняются начальные условия, граничные условия и условия склеивания на границе воздух-среда:

$$E_\varphi|_{t<0} \equiv 0, E_\varphi|_{r<0} \equiv 0, [E_\varphi]_0 = 0, E_{\varphi,z}|_0 = 0. \quad (12)$$

Измерения проводятся на поверхности  $z = 0$ :

$$E_\varphi|_{z=+0} = \varphi(r, t). \quad (13)$$

Нам нужно определить функцию источника георадара (см. (10)), предполагая, что электромагнитная компонента  $E_\varphi$  удовлетворяет прямой задаче (11)-(12), а также граничному условию (13). Решение задачи определим частотной области. С этой целью применим преобразования Лапласа и Ханкеля:

$$u(v, z, p) = \int_0^\infty e^{-pt} \int_0^\infty r E_\varphi(r, z, t) J_1(vr) dr dt, \quad (14)$$

где  $p = \alpha + i2\pi f$  - параметр преобразования Лапласа ( $\alpha$ -коэффициент затухания,  $f$ - временная частота в Гц);

$J_1(r)$  - функция Бесселя первого порядка.

Используем обозначения:  $\varphi(v, p)$  - образ функции  $\varphi(r, t)$ ,  $f(p)$  - образ функции  $f(t)$  по Лапласу,  $g(v)$ - преобразование Ханкеля функции  $g(r)$ .

Тогда имеет место:

$$g(v) = \int_0^\infty r \theta(r_0 - r) J_1(vr) dr = \frac{\sqrt{\pi} r_0}{2v} (J_1(r_0 v) \mathcal{H}_0(r_0 v) - J_0(r_0 v) \mathcal{H}_1(r_0 v)),$$

где  $J_n(r)$  и  $\mathcal{H}_n(r)$ - функции Бесселя и Струве  $n$ -го порядка (см., например, [94; 95, p. 465-478]).

Тогда функция  $u(v, z, p)$  удовлетворяет уравнению:

$$u_{zz} - (v^2 + p^2 \mu_{\varepsilon_0 \varepsilon} + p \mu \sigma) u = \mu p f(p) g(v) \delta(z - z^*), \quad z \in (-\infty, \infty) \quad (15)$$

Рассматривая решения уравнения (15) на интервалах  $(-\infty, z^*)$ ,  $(z^*, 0)$ ,  $(0, \infty)$ , и учитывая условия затухания на бесконечности, и используя условия сшивки в точке  $z^*$  и на границе раздела сред, при пределе  $z^* \rightarrow 0$  имеем:

$$-\mu p f(p) g(v) = (k_m + k_0) u(v, +0, p) = (k_m + k_0) \varphi(r, t), \quad (16)$$

где

$$k_m = \sqrt{v^2 + p^2 \mu_{\varepsilon_0 \varepsilon_m} + p \mu \sigma_m}, \quad k_0 = \sqrt{v^2 + p^2 \mu_{\varepsilon_0}}, \quad \text{Re}\{r_m\} > 0, \text{Re}\{r_0\} > 0.$$


На основе соотношения (16) построить алгоритм восстановления функции источника  $f(t)$ .

#### *Экспериментальные исследования*

На песчаном карьере близ села Сабынды Акмолинской области, были проведены экспериментальные исследования с применением георадара серии Лоза-В. Использованы антенны с разверткой 0.5 метров, 1 -метр.

Для эксперимента использовался георадар «Лоза-В», работающий на частотах  $f^{(1)}=150$  и  $f^{(2)}=300$  МГц.

На рисунке 37а – модель носителя и расположение источника и приемников. 37б - процесс измерений с помощью георадара «Лоза-В» в песчаном карьере.



а

б

а – схема расположения источника и приемников; б – процесс измерений с помощью георадара «Лоза-Б» в песчаном карьере

Рисунок 37 – а, б – Эксперимент «Лоза-В»

Примечание – Составлено по источникам [13, с. 23-44; 15]

Известная среда представляла собой сухой песок с относительной диэлектрической проницаемостью  $\epsilon_m = 6$  и проводимостью  $\sigma_m = 5 \cdot 10^{-4} \text{См/м}$ . Электромагнитные волны возбуждались источником вида (1). Приёмники электромагнитных волн располагались на поверхности  $z = 0$  с шагом  $h=0,5$  м по одной прямой линии (см. рисунок 29а).

На рисунок 37 (б) показан процесс измерений с использованием георадара.

Как отмечалось выше, приёмники регистрировали компоненту электромагнитного поля  $E_\varphi$  в точках  $(r_i, 0, t), i = 1, N_r, t \in [0, T], T = 50(\text{нс})$ . Толщина скин-слоя определяется формулой (17):

$$z_s = \frac{1}{\sqrt{\pi f \mu \sigma}} \quad (17)$$

и на расстоянии  $r \geq L_r$  амплитуда уменьшается более чем в 140 раз. Поэтому аппроксимация  $E_\varphi(r, 0, t) = 0$  для  $r \geq L_r$  является правильной.

Данные  $E_\varphi(r_i, 0, t)$  подвергались фильтрации (см. [103]). Из теоремы Котельникова [103, с. 736-743] следует, что используемые частоты преобразования Фурье не должны превышать частоты Найквиста  $\nu_{max} = 1/2h$  [104, р. 617-643]. Поскольку функция Бесселя  $J_1(r)$  ведёт себя как затухающая синусоида, частота Найквиста также задает ограничение на пространственные частоты  $\nu$ . Из [71, о. 225; 92, р. 84-90] известно, что частота  $\nu$  должна удовлетворять неравенству:  $\nu \leq 2\pi f$ . Таким образом, для вычисления преобразования (16) частоты  $\nu$  выбираются с учетом обоих неравенств. Приближённое вычисление преобразования (16) можно записать в виде:

$$u(v, z, p) = \int_0^\infty e^{-pt} \int_0^\infty r E_\varphi(r, z, t) J_1(vr) dr dt \approx \sum_{j=0}^{N_r} e^{-pt_j} \sum_{i=1}^{N_r} r_i E_\varphi(r_i, z, t_j) J_1(vr_i)$$

где шаг по времени  $\tau$ , а частоты  $f$  выбираются из интервалов  $[f^{(k)} - \delta, f^{(k)} + \delta](k = 1, 2)$ .

Коэффициент затухания  $\alpha$  определяется из условия  $\alpha = 2z_s \sqrt{\mu \varepsilon_m}$  [92, p. 894-90].

#### 4.2 Метод определения параметров источника на основе применения оптимизационного метода

Георадар имеет возможность генерировать зондирующие сигналы только на нескольких временных частотах, в нашем случае - на двух. Это означает, что для каждой рабочей частоты  $f^{(k)}$  в преобразовании (14) используются временные частоты лишь из узких интервалов  $[f^{(k)} - \delta, f^{(k)} + \delta](k = 1, 2)$ .

При проектировании антенны, генерирующей зондирующий сигнал, производитель сообщает пользователю тип источника, то есть форму функции  $f(t)$ . Она зависит от конструкции георадара и, как правило, может быть хорошо аппроксимирована затухающей синусоидой:

$$f(t) = R e^{-2\pi f_0 t} \sin(2\pi f_0 t) \quad (*)$$

где  $f_0$  - доминирующая частота (в георадаре она совпадает с одной из рабочих частот);

$R$  - амплитуда источника.

В работе функция источника предполагается в виде:

$$f(t) = \rho R e^{-2\pi \beta f_0 t} \sin(2\pi \gamma f_0 t) \quad (**)$$

а её преобразование Лапласа имеет вид  $f(p) = \frac{2R\rho\gamma f_0}{(p - 2\pi\beta f_0)^2 + (2\pi\gamma f_0)^2}$ .

Очевидно, что параметры  $\rho, \beta, \gamma$  являются корректирующими и определяют точную форму функции  $f(t)$ . Иными словами, именно эти параметры отвечают за калибровку источника георадара.

Используя равенство (19), определим функционал невязки  $\Phi(\rho, \beta, \gamma)$  в виде:

$$\Phi(\rho, \beta, \gamma) = \sum_{n=1}^N |\varphi(v, p_n) + \mu g(v) \frac{p_n}{k_{m,n} + k_{0,n}} \frac{2R\rho\gamma f_n}{(\rho - 2\pi\beta f_n)^2 + (2\pi\gamma f_n)^2}|^2 \quad (18)$$

$$k_{m,n} = \sqrt{v^2 + p_n^2 \mu_{\varepsilon_0 \varepsilon_m} + p_n \mu \sigma_m}, \quad k_{0,n} = \sqrt{v^2 + p_n^2 \mu_{\varepsilon_0}},$$

$$p_n = \alpha + i2\pi f_n, \quad (n = \overline{1, N}),$$

где частоты  $f_n$  выбираются из интервалов  $[f^{(k)} - \delta, f^{(k)} + \delta]$  (обычно с равными шагами).

Таким образом, задача восстановления неизвестной функции источника  $f(t)$  сводится к задаче минимизации функционала  $\Phi(\rho, \beta, \gamma)$  по трем параметрам  $\rho, \beta, \gamma$ .

Минимум функционала (20) может быть найден методом сопряженных градиентов (см., например, [114]). Градиент  $\nabla\Phi(\rho, \beta, \gamma) = (\Phi'_\rho, \Phi'_\beta, \Phi'_\gamma)$ , где каждая производная может быть вычислена численно по формулам вида:

$$\Phi'_\rho = \begin{cases} 0 & \\ \frac{\Phi(\rho + \delta_\rho, \beta, \gamma) - \Phi(\rho - \delta_\rho, \beta, \gamma)}{2\delta_\rho} & , \text{ если } \Phi(\rho + \delta_\rho, \beta, \gamma) \leq \Phi(\rho, \beta, \gamma), \\ \Phi(\rho - \delta_\rho, \beta, \gamma) \leq \Phi(\rho, \beta, \gamma), \end{cases} \quad (19)$$

иначе, аналогично вычисляются  $\Phi'_\beta$  и  $\Phi'_\gamma$ . Подобные формулы впервые использовались в работе [20, с. 251-253; 21, с. 55-64]. Величина шага  $\delta\rho$  (и аналогичные шаги для  $\beta, \gamma$ ) подбирается на основе численного эксперимента с модельными данными: выбирается такое значение, при котором минимизация функционала достигается за наименьшее число итераций. Разумным выбором является  $\delta_\rho = 10^{-6}$ .

Для начала процесса минимизации методом сопряженных градиентов необходимо задать начальное приближение. В качестве таковых можно взять:  $\rho_{[0]} = 1, \beta_{[0]} = 1, \gamma_{[0]} = 1$ , или же значения, полученные при предыдущей калибровке источника.

Замечание. В зависимости от конструкции георадара в качестве модели источника могут использоваться и другие формы импульсов: Гауссовский, импульс Рикера («мексиканская шляпа»), источник Пузырёва и др. В этом случае предложенный математический алгоритм остаётся без изменений; меняется лишь выражение для преобразования Лапласа  $f(p)$ .

*Калибровка (уточнение формы источника)*

Калибровка источника выполняется отдельно для каждой рабочей частоты георадара. Рабочая частота  $f^{(k)}$ , интервал рабочих частот, из которого выбирались частоты  $f$  для построения функционала (20), а также их количество  $N$  приведены в таблице 9.

Таблица 9 – Количество  $N$

k	$f^{(k)}$ , (МГц)	Интервал (МГц)	N
1	150	[130,170]	5
2	300	[280,320]	5

Параметры  $\rho, \beta, \gamma$ , найденные после обработки практических измерений (см. рисунок 37), собраны в таблице 10.

Таблица 10 – После обработки

k	$f^{(k)}$ , (МГц)	$\rho$	$\beta$	$\gamma$
1	150	1.01	1.13	1.21
2	300	1.03	1.09	1.18

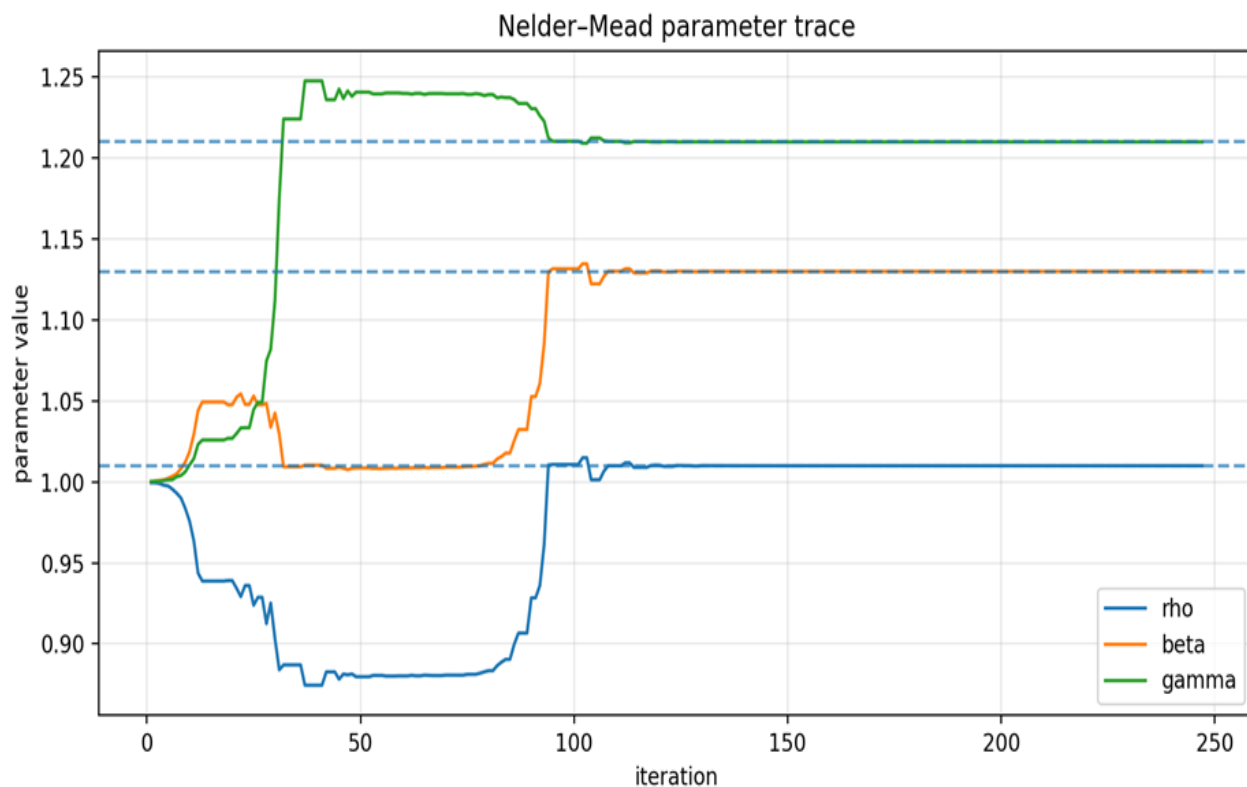


Рисунок 38 – Результаты итерационного метода определения параметров источника

Примечание – Составлено по источнику [11, с. 228]

На рисунке 38 приведены результаты оптимизационного метода определения параметров источника. Как видно из графика значения параметров источника указанных в таблице 11, получены в результате итерации 120 шагов.

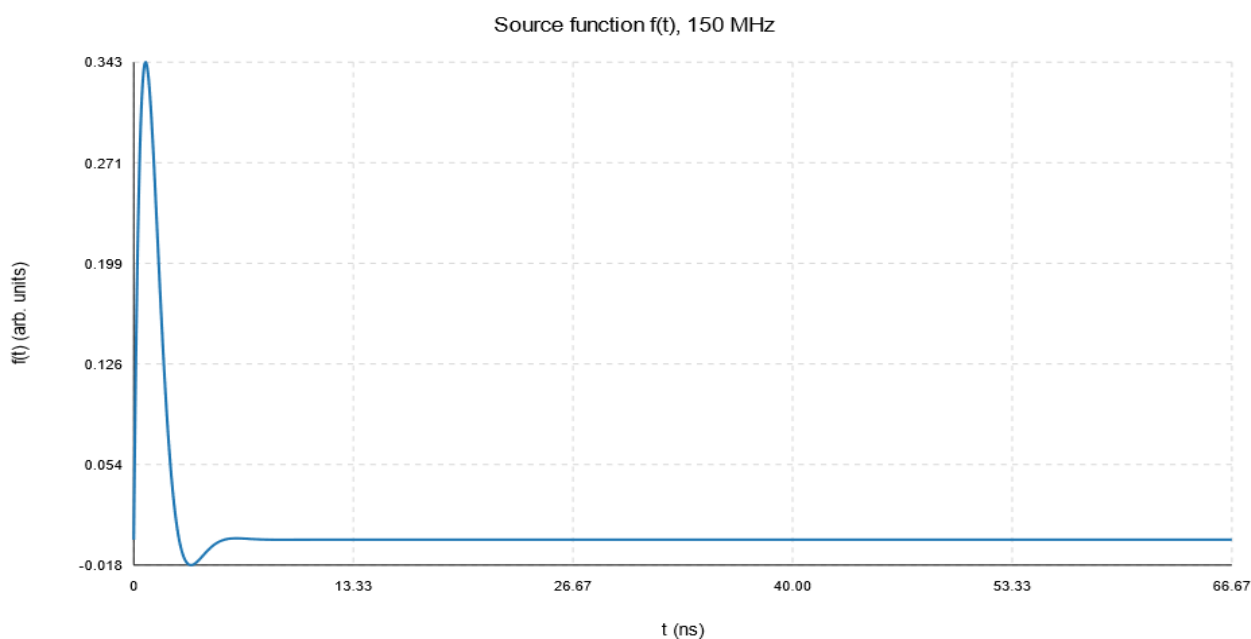



Рисунок 39 – Калиброванная форма источника

Примечание – Составлено по источнику [11, с. 228]

На рисунке 39 представлена окончательная форма калибровочной функции источника. Причем мы имеем ее значения в табличной форме, которая крайне необходима в дальнейшем для определения параметров подстилающего слоя.

#### 4.3 Метод решения обратной задачи по определению диэлектрической проницаемости и проводимости включений в подстилающей среде

Во время эксплуатации может происходить деформирование дорожного покрытия из-за природных условий, например поднятия грунтовых вод, техногенных явлений, например нарушения целостности грунта, потеря его однородности, содержания в грунте крупного инородного объекта, и т.д. Рассмотрим задачу прогноза как задачу определения электромагнитных параметров грунта. Сухой грунт имеет некоторую диэлектрическую проницаемость. Если влажность грунта увеличилась в следствие присутствия грунтовых вод, то относительная диэлектрическая проницаемость грунта тоже увеличится. Имея корреляционную зависимость влажности от относительной диэлектрической проницаемости, по её значению можно определить значение влажности грунта. При критических значениях влажности для предотвращения разрушения дорожного полотна следует провести работы по водоотведению (рисунок 40).



а – типовое строение дорожного покрытия: 1) асфальтобетон (4 см) или слой мелкозернистого асфальта (1 см) и слой крупнозернистого асфальта (3 см); 2) мелкий щебень (6 см); 3) крупный щебень (25 см); 4) щебёночно-песочная смесь (35 см); 5) грунт; б – модель среды: горизонтально-слоистая структура с границами раздела  $z_n$  ( $n=0, M$ ),  $n$ -ый слой – это интервал  $[z_{n-1}, z_n]$ , толщина  $n$ -ого слоя  $h_n = z_n - z_{n-1}$ ,  $z < 0$  – воздух,  $z > z_M$  – подстилающий слой

Рисунок 40 – Типовое строение дорожного покрытия

Примечание – Составлено по источнику [105]

Предположим, что свойства среды зависят только от глубины. Прямые и обратные задачи будем рассматривать в частотной области. Большое количество обратных задач в частотной области по определению электромагнитных, упругих или каких-либо других свойств среды сводятся к постановкам обратных задач для дифференциальное уравнение 2-ого порядка:

$$(a_1 y_z)_z + a_2 y_z + a_3 y = g(y, p) \delta(z - z_*). \quad (20)$$

(или к системе дифференциальных уравнений второго порядка).

Как правило, для решения (20) либо известно на поверхности краевое условие вида:

$$(y_z + m_1 y)|_{z=0} = m_2, \quad (21)$$

либо в воздухе предполагается условие затухания

$$y|_{z \rightarrow -\infty} = 0, \quad (22)$$

в подстилающем слое предполагается условие затухания

$$y|_{z \rightarrow \infty} = 0. \quad (23)$$

Постановка (21)-(22) является прямой задачей.

Обратная задача: определить неизвестные функции  $v_i$ , если о решении прямой задачи (23)-(24) известна дополнительная информация вида:

$$y|_{z=0} = \eta(v, p) \quad (24)$$

Стандартный подход при численном решении обратной задачи, состоит в минимизации квадратичного функционала невязки наблюдаемых и расчетных компонент электромагнитного поля.

При стандартном подходе прямую задачу нужно многократно решать во всей области, где она поставлена. Если функции  $v_i$  известны на части области и требуется определение функций  $v_i$  на другой части области, прямая задача решается на всей области. Из-за размеров области такой порядок вычислений потребует много времени для численного расчета. Поэтому мы будем решать задачу определения горизонтальной компоненты электрического поля вплоть до глубины залегания грунта, где коэффициенты  $v_i$ , известны, а затем на втором этапе поставить и решать обратную задачу на меньшей области, там, где они неизвестны.

Конкретизируем постановки прямой и обратной задачи.

*Постановка прямой задачи:* определить решение следующей задачи, при условии, что все параметры входящие в уравнение, а также граничные условия известны из следующих соотношений:

$$w_{zz} - k^2 w = 0, \quad (25)$$

$$(w_z - k_0 w)|_{z=0} = (w_z - k_0 w)|_{z=0} = 0 \quad (26)$$

$$w|_{z \rightarrow \infty} = 0, \quad (27)$$

$$[w_z]_{zn} = 0, [w]_{zn} = 0; \quad n = 1, M. \quad (28)$$

где  $k(z) = \sqrt{v^2 + p^2 \mu \varepsilon_0 \varepsilon(z) + p \mu \sigma(z)}$  и  $Re \{k(z)\} > 0$ , в  $n$ -ом слое  $k_n = \sqrt{v^2 + p^2 \mu \varepsilon_0 \varepsilon_n + P \mu \sigma_n}$ , в воздухе  $k_0 = \sqrt{v^2 + p^2 \mu \varepsilon_0}$ .

Постановка обратной задачи: Определить  $\varepsilon_{M+1}$  и  $\sigma_{M+1}$ , если известно, что функция  $\omega(v, z, p)$  удовлетворяет постановке прямой задачи (25)-(28), по известной дополнительной информации:

$$w|_{z=0} = 0 = \xi(v, p), \quad (29)$$

а также полагаем, что известны  $\varepsilon_n$  и  $\sigma_n$  ( $n = 1, M$ ).

Отметим, постановка прямой задачи (24)-(27), непосредственно вытекает из физически обоснованных выкладок [17, с. 3-236; 18, с. 3-318].

Продолжим важные рассуждения. Так как  $\varepsilon_n$  и  $\sigma_n$  ( $n = 1, M$ ) известны, рассмотрим задачу определения граничного условия: найти решение дифференциального уравнения (25), удовлетворяющее первому краевому условию в (26) и краевому условию (27). Таким образом суть поставленной обратной задачи состоит в определении величины  $w_z|_{z=z_m}$  и  $w|_{z=z_m}$

Для получения аналитических выражений решения задачи об определении граничного условия мы используем метод послойного пересчёта. Впервые этот метод послойного пересчёта для решения краевой задачи для дифференциального уравнения второго порядка в горизонтально-слоистой среде был разработан в работе Тихонова–Шахсуварова [20, с. 251-253]. В дальнейшем этот метод был улучшен в работах Дмитриева [21, с. 55-64; 22, с. 150-182].

Далее этот метод послойного пересчёта был развит для уравнений Максвелла (горизонтально-слоистая среда произвольного типа анизотропии [44, р. 4-19]); для системы уравнений конвективного переноса тепла и влаги [45, р. 1029-1036]; для дифференциального уравнения четвертого порядка о поперечных колебаниях кусочно-однородной балки [46, р. 415-419]. В настоящее время метод послойного пересчёта для решения краевых задач для дифференциальных уравнений второго порядка или систем дифференциальных уравнений второго порядка для горизонтально-слоистых сред признан наиболее удобным для вычислений.

Метод послойного пересчёта позволяет получить численный метод решения прямой задачи, который не только устойчив к ошибкам округления, но и требует относительно малого времени на вычисления. Время решения прямой и, соответственно, обратной задачи может быть существенно сокращено, если необходимо решать обратную задачу определения параметров среды, начиная с некоторой глубины, так как верхняя часть среды известна. Это может быть, например, дорожное покрытие, взлётно-посадочная полоса аэродрома, верхняя часть геологического разреза и т. д. Решив задачу об определении граничного условия на некоторую глубину и исключив информацию о соответствующих слоях из известных данных, мы получаем более простую постановку обратной задачи.

*Алгоритм определения параметров подстилающего слоя*

Для определения величин  $w_z|_{z=z_m}$  и  $w|_{z=z_m}$

организуем вычисления следующим образом [14, с. 89-96]:

1. Вычислим  $\alpha_n$  и  $\beta_n$  ( $n = 1, M$ ) рекуррентно

$$\alpha^0 = k_0, \quad \alpha^n = k_n \frac{((\alpha^{n-1} + k_n) + (\alpha^{n-1} - k_n)e^{-2k_n h_n})}{((\alpha^{n-1} + k_n) - (\alpha^{n-1} - k_n)e^{-2k_n h_n})} \quad (30)$$

$$\beta^0 = \mu p f(p) g(v), \quad \beta^n = \beta^{n-1} \frac{2k_n e^{-k_n h_n}}{(\alpha^{n-1} + k_n) - (\alpha^{n-1} - k_n)e^{-2k_n h_n}}, \quad (31)$$

2. Зная величины  $\alpha^n$  и  $\beta^n$  ( $n = 1, M$ ), вычислим  $w_n$  ( $n = 1, M$ ) рекуррентно  $\omega_0 = \xi(v, p)$ .

Уравнение для  $\omega$  имеет вид:

$$w = \frac{2k_n}{[(\alpha^n + k_n)e^{-2k_n h_n} - (\alpha^n - k_n)]} (w_{-1} e^{-k_n h_n} - \beta \frac{1 - e^{-2k_n h_n}}{2k_n}) \quad (32)$$

Величины

$$w_z|_{z=zM} = \alpha^M w_M + \beta^M, \quad w_z|_{z=z_m} = w_m$$

уже вычислены. Отметим, в выражениях (30)-(31) присутствуют экспоненты, у которых действительные части показателей отрицательные. Это означает, что вычисление необходимых величин и рекуррентный пересчёт будут обходиться без накопления ошибок округлений.

Используя вычисленные (32) и условие затухания (31), получим окончательно:

$$k_{M+1} = -\frac{\beta_M}{\omega_M} - \alpha^M \Rightarrow p\varepsilon_0 \varepsilon_{M+1} + \sigma_{M+1} = \frac{1}{p\mu} [(\frac{\beta^M}{\omega_M} + \alpha^M)^2 - \vartheta^2] \equiv \chi, \quad (33)$$

откуда следует

$$\varepsilon_{M+1} = \frac{1}{\varepsilon_0 \omega} \operatorname{Im}\{\chi\}, \quad \sigma_{M+1} = \frac{\gamma}{\omega} \operatorname{Im}\{\chi\} - \operatorname{Re}\{\chi\}. \quad (34)$$

Далее для вывода формул вычисления параметров подстилающего слоя, используем полученные в предыдущем пункте данные калибровочной функции описывающий источник. Форма функции источника  $f(t)$  зависит от конструкции георадара и хорошо аппроксимирована затухающей синусоидой:

$$f(t) = R e^{-2\pi f_0 t} \sin(2\pi f_0 t), \quad (*)$$

где  $f_0$  - доминирующая частота (в георадаре она совпадает с одной из рабочих частот);

$R$  - амплитуда источника.

Мы предполагаем в виде  $f(t) = \rho R e^{-2\pi\beta f_0 t} \sin(2\pi\gamma f_0 t)$  (\*\*)

а её преобразование Лапласа имеет вид  $f(p) = \frac{2R\rho\gamma f_0}{(p - 2\pi\beta f_0)^2 + (2\pi\gamma f_0)^2}$ .

Параметры  $\rho$ ,  $\beta$ ,  $\gamma$  являются корректирующими и определяют точную форму функции  $f(t)$ .

Параметры  $\rho$ ,  $\beta$ ,  $\gamma$ , найденные после обработки практических измерений (см. рисунок 38б), собраны в таблице 11.

Таблица 11 – Восстановление диэлектрической проницаемости подсылающий слое

k	$f^{(k)}$ , МГц	Диэлектрическая проницаемость грунта $f^{(k)}$ , MHz	Восстановление Проницаемость $\epsilon_{M+1}$	Проводимость грунта restored $\epsilon_{M+1}$	Восстановленная Проводимость restored $\sigma_{M+1}$
1	150	5.00	7.76	0.0010	0.1796
2	300	5.00	3.18	0.0010	-0.0649
3	100	5.00	10.56	0.0010	-0.4675
Примечание – Составлено по источнику [11, с. 226]					

Используя найденные параметры  $\rho$ ,  $\beta$ ,  $\gamma$  (см. таблица 11), определим относительную диэлектрическую проницаемость и проводимость суглинистого песчаного грунта вблизи песчаного карьера.

Данные георадара были измерены и обработаны при  $\alpha=0$ . Из соотношения (18) следует:

$$k_m = -k_0 - 2i\pi\mu f \frac{f(2i\pi f)g(v)}{\varphi(v, 2i\pi f)}, \text{ и в этом случае } \epsilon_m = \frac{v^2 - \text{Re}\{k_m^2\}}{\mu_{\epsilon_0}(2\pi f)^2}, \sigma_m = \frac{\text{Im}\{k_m^2\}}{\mu 2\pi f}$$

Результаты вычислений представлены в таблице 11:

Из таблицы 11, убеждаемся, что получен удовлетворительный результат восстановления электромагнитных параметров подстилающего грунта [11, с. 226-232].

### Выводы к четвертому разделу

Представлен процесс калибровки функции источника георадара, изложены его математические основы и приведены результаты калибровки на данных, измеренных в песчаном карьере, где электромагнитные параметры зондирующей среды известны. Полученные значения параметров, характеризующих поведение источника, могут считаться известными и использоваться для численного решения задач по определению неизвестных электромагнитных параметров среды с помощью алгоритмов, не встроенных в программное обеспечение георадара.

При определении относительной диэлектрической проницаемости  $\epsilon_{M+1}$  и проводимости  $\sigma_{M+1}$  подстилающего слоя (грунта дорожной одежды) решение задачи об определении граничного условия позволило не решать обратную задачу оптимизационным методом, а получить рекуррентные формулы (32)-(34).

Основные результаты данного раздела опубликованы в работах [11, с. 226-232; 12, с. 519-523].

## ЗАКЛЮЧЕНИЕ

1. Результаты расчетов, проведенных нами на реальных данных, подтверждены с данными глубины объектов, в частности, в первом эксперименте с куполом торфа, который находился на глубине порядка 0.8метра, по данным радарограммы, на позиции 0.78метра, во втором примере пластиковые бутылки были закопаны на глубине 0.35 метров, были обнаружены на глубине 0.33 метров. Таким образом, абсолютная погрешность составила порядка 0,2-0,3 см.

Существующие в настоящее время программные средства обработки георадарных данных не раскрывают использованных методов определения глубины залегания подповерхностных объектов. Встроенные в георадар математическое и программное обеспечение, лежащее в основе интерпретации радарограмм, недоступны для анализа.

Наличие собственного программного модуля определения глубины залегания подповерхностных объектов позволяет апробировать алгоритмы, с учетом необходимых свойств подповерхностной среды.

2. Нами проведены экспериментальные исследования с помощью георадара серии «Лоза-В», с целью тестирования методики профессора А.В. Старовойтова для первичной обработки реальных экспериментальных данных георадара. Этот метод в сочетании с программным обеспечением георадарного комплекса, позволяет очистить радарограмму от шумов и различных помех и получить окончательный результат, а именно переход от временного разреза к глубинному. То есть получить геоэлектрический разрез, а именно геоэлектрические свойства неоднородной среды. Антенны георадара фиксируют только время пробега электромагнитного сигнала от неоднородности и является функцией от времени. Глубина проникновения этого сигнала зависит от свойств источника и от антенны. С другой стороны, если сигнал попадает в среду с высокой электромагнитными свойствами, например неоднородный объект, а также с высокой влажностью, то этот объект сам является источником вторичных волн. В связи с этим нами рассмотрен пример с объектом купола торфа, который даже в сухом состоянии обладает высокой диэлектрической проницаемостью. В случае, если подстилающий слой в дорожной одежде имеет высокую влажность, то такой грунт имеет порядок диэлектрической проницаемости порядка 50-80 единиц. В связи с этим проведены нами, во второй части этой статьи экспериментальные исследования по установлению корреляционной зависимости диэлектрической проницаемости и влажности. Последнее позволяет прогнозировать состояние подстилающего грунта.

Разработанная и протестированная методика на основе экспериментальных данных может быть использованы при георадарных исследованиях в различных задачах естествознания, например при прогнозировании дефектов подповерхностных слоёв дорожных конструкций, исследовании строительных участков, а также в задачах археологии.

3. Результаты данного исследования ясно демонстрируют превосходство модели LSTM (долгой кратковременной памяти) в прогнозировании

структурного состояния подповерхностных слоёв дорожных конструкций. При  $RMSE = 3.01$  и коэффициенте корреляции ( $CC$ ) = 0.92 модель LSTM превзошла все остальные протестированные модели, показав высокую точность прогнозирования и сильную способность к обобщению на новые данные. Эти результаты, подтверждённые визуальными анализами на рисунках 3 и 4, указывают на способность модели LSTM улавливать сложные временные зависимости в наборе данных. Архитектура LSTM особенно хорошо подходит для последовательными временных данных, что критически важно для задач мониторинга инфраструктуры, где состояние покрытия изменяется с течением времени. Для сравнения, модели на основе ANN, особенно гибридная ANN-GWO, также показали обнадеживающие результаты. Модель ANN-GWO достигла  $RMSE = 3.55$  и  $CC = 0.89$ , что демонстрирует эффективность нейронных сетей, интегрированных с алгоритмами оптимизации, в прогнозировании подобных процессов. Однако разница в производительности между ANN-GWO и LSTM указывает на то, что традиционные ANN-модели могут иметь ограниченные возможности при обучении долговременным зависимостям или моделировании нелинейных процессов деградации. Это наблюдение согласуется с предыдущими исследованиями, подтверждающими преимущества методов глубокого обучения для задач временных рядов и мониторинга структурного состояния.

Другие модели, такие как ANN-PSO и стандартная ANN, продемонстрировали средний уровень эффективности, в то время как XGBoost и SGD оказались менее результативными в данном контексте. Это, вероятно, связано с тем, что указанные методы не предназначены для анализа временных зависимостей. Например, XGBoost хорошо работает со структурированными данными, но не имеет внутренней памяти, необходимой для моделирования динамических, зависящих от времени процессов. А сравнительно слабая производительность SGD объясняется его чувствительностью к распределению данных и ограниченной способностью моделировать нелинейности без сложной настройки гиперпараметров или инжиниринга признаков. В совокупности эти результаты подчёркивают, что точность прогнозирования не должна быть единственным критерием при выборе модели. Не менее важно учитывать, насколько хорошо модель способна обобщать результаты на реальные условия и отражать внутреннюю динамику изучаемой системы. Модель LSTM, удовлетворяя обоим критериям, представляет собой оптимальный вариант для практического применения в мониторинге подповерхностных слоёв дорожных конструкций. Её способность обучаться на исторических данных и предсказывать будущую деградацию делает её особенно ценной для прогнозного обслуживания и долгосрочного планирования инфраструктуры. Эти выводы согласуются с современными исследованиями, в которых подчеркивается важность глубокого обучения в управлении транспортными активами. Кроме того, результаты данного исследования указывают на перспективные направления дальнейших работ, включая: разработку ансамблевых и гибридных методов обучения, интеграцию данных о дорожных покрытиях и трафике в единые модели, применение объяснимого искусственного интеллекта

(ExplainableAI) для повышения интерпретируемости моделей. Внедрение таких продвинутых моделей, как LSTM, в операционные системы мониторинга позволит транспортным агентствам сделать значительный шаг к умному, эффективному и устойчивому управлению инфраструктурой.

Настоящее исследование демонстрирует, что глубокое обучение (DeepLearning) может служить надёжным инструментом для моделирования мониторинга структурного состояния подповерхностных слоёв дорожных конструкций. Учитывая ключевые факторы, такие как температура асфальта и толщина покрытия, предложенная модель смогла с высокой точностью предсказать состояние дорожного покрытия и его последующую деградацию, что было подтверждено полевой валидацией с использованием данных HWD (HeavyWeightDeflectometer - тяжёлого падающего дефлектометра) и GPR (GroundPenetratingRadar - георадара). По сравнению с традиционными методами и другими подходами машинного обучения, модель глубокого обучения показала себя как более эффективная и надёжная, способная работать со сложными наборами данных и поддерживать проактивное техническое обслуживание и долгосрочное управление дорожной инфраструктурой. Среди протестированных моделей модель LSTM (LongShort-TermMemory) показала наилучшую производительность и наивысший коэффициент корреляции, за ней следует модель ANN-GWO (искусственная нейронная сеть с оптимизацией серого волка), которая была несколько менее точной, но всё же высокоэффективной [106-108].

Модели ANN-PSO и ANN показали умеренные результаты, тогда как XGBoost и особенно SGD проявили себя слабо, при этом SGD оказался непригодным для данного типа задач. На основании этих результатов модели LSTM и ANN-GWO рекомендуется использовать на практике. Интеграция таких моделей в системы умных городов (SmartCity) позволит реализовать оперативный, экономичный и ненавязчивый мониторинг подповерхностных слоёв дорожных конструкций, что поможет транспортным ведомствам повысить безопасность дорожного движения, сократить расходы на обслуживание и продлить срок службы дорог. С практической точки зрения транспортным агентствам следует рассмотреть внедрение систем мониторинга, основанных на искусственном интеллекте, а также интеграцию данных от сенсоров, трафика и факторов окружающей среды в единые аналитические платформы для повышения качества управленческих решений. На уровне политики необходимы поддерживающие нормативные и организационные рамки, способствующие развитию предиктивных стратегий технического обслуживания, которые позволят эффективнее использовать ограниченные бюджеты, одновременно повышая общественную безопасность и устойчивость инфраструктуры. Одним из ограничений данного исследования является то, что оно рассматривает лишь определённый набор методов машинного обучения, что означает, что некоторые потенциально полезные подходы могли быть упущены. В дальнейшем исследовании следует тестировать более широкий спектр моделей и использовать более крупные и разнообразные наборы данных, включающие различные типы покрытий, дорог и климатических условий. Также важно

проверить модели в разных регионах, чтобы определить, насколько хорошо они работают в реальных эксплуатационных условиях. Кроме того, будущие исследования должны быть направлены на усовершенствование автоматического выявления дефектов подповерхностных слоёв дорожных конструкций с применением объяснимого искусственного интеллекта (ExplainableAI) для повышения прозрачности и доверия к результатам, а также на тестирование гибридных, ансамблевых и методов переноса обучения (TransferLearning), которые могут повысить точность в условиях различных климатов и распределений данных. Комбинирование прогнозирования транспортных потоков с мониторингом подповерхностных слоёв дорожных конструкций посредством пространственно-временного моделирования (spatiotemporal modeling) может привести к созданию унифицированных систем управления городской мобильностью и инфраструктурой, способствуя реализации концепции умных, устойчивых и устойчивых к изменениям городов.

4. Представлен процесс калибровки функции источника георадара, изложены его математические основы и приведены результаты калибровки на данных, измеренных в песчаном карьере, где электромагнитные параметры зондирующей среды известны. Полученные значения параметров, характеризующих поведение источника, могут считаться известными и использоваться для численного решения задач по определению неизвестных электромагнитных параметров среды с помощью алгоритмов, не встроенных в программное обеспечение георадара.

5. Разработан алгоритм определения горизонтальной компоненты электрической напряженности на некоторой глубине, когда электромагнитные свойства первых нескольких слоев известны, а свойства подстилающей среды подлежат определению. Нами представлен численный алгоритм определения диэлектрической проницаемости подстилающего слоя. В такой постановке отпадает необходимость решения обратной задачи оптимизационным методом. При определении относительной диэлектрической проницаемости  $\epsilon_{M+1}$  и проводимости  $\sigma_{M+1}$  подстилающего слоя (грунта дорожной одежды) решение задачи об определении граничного условия позволило не решать обратную задачу оптимизационным методом, а получить рекуррентные формулы на основе аналитического решения.

## СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

- 1 Президент Республики Казахстан К.-Ж. Токаев. Казахстан в эпоху искусственного интеллекта: актуальные задачи и их решения через цифровую трансформацию // <https://www.inform.kz/ru/polniy-tekst-poslaniya>. 10.10.2025.
- 2 Георадар «Лоза-В»: технический обзор и область применения // <https://www.nep.expert/tehbaza/georadar-loza-b/>. 10.10.2025.
- 3 Тихонов А.Н., Арсенин В.Я. Методы решения некорректных задач. – М.: Наука, 1979. – 285 с.
- 4 Лаврентьев М.М., Романов В.Г., Шишатский С.П. Некорректные задачи математической физики и анализа. – Новосибирск, 1980. – 286 с.
- 5 Романов В.Г. Обратные задачи математической физики. – М.: Наука, 1984. – 363 с.
- 6 Романов В.Г., Кабанихин С.И. Обратные задачи геоэлектрики: теоремы существования и единственности. – М.: Наука, 1986. – 50 с.
- 7 Кабанихин С.И., Исаков К.Т. Оптимизационные методы решения коэффициентных задач. – Новосибирск, 2001. – 316 с.
- 8 Исаков К.Т. Алгоритмы интерпретации радарограмм // Матер. 15-й междунар. молод. науч. школы-конф. «Теория и численные методы решения обратных и некорректных задач». – Новосибирск, 2023. – С. 23-24.
- 9 Azodinia M., Iskakov K., Orman I. et al. Deep Learning for Structural Health Monitoring of Pavements for Improving Road Maintenance and Management // Decision Making: Applications in Management and Engineering. – 2025. – Vol. 8, Issue 2. – P. 863-880.
- 10 Orman I.M., Kurmashev I.G., Karchevsky A.L. Continuation problem of the electromagnetic field in the frequency domain for horizontally layered media // Eurasian Journal of Mathematical and Computer Applications. – 2024. – Vol. 12, Issue 3. – P. 105-116.
- 11 Orman I. M., Boranbayev S.A., Kurmashev I.G. et al. Gpr sounding source calibration // Вестник Национальной инженерной академии Республики Казахстан. – 2024. – №2(92). – С. 226-233.
- 12 Курмашев И.Г., Орман И.М., Боранбаев С.А. Определения глубины залегания включения в подстилающей среде // Труды университета. – 2024. – №1(94). – С. 519-524.
- 13 Определение глубины залегания включения в подстилающей среде // Матер. 15-й междунар. молод. науч. школы-конф. «Теория и численные методы решения обратных и некорректных задач». – Новосибирск, 2023. – С. 23-45.
- 14 Орман И.М. и др. Проблема продолжения электромагнитного поля в частотной области для горизонтально слоистых сред // Матер. 16-й междунар. молод. науч. школы-конф. «Определение калибровочной функции зависимости диэлектрической проницаемости от влажности». – Новосибирск, 2024. – С. 89-97.
- 15 А.С. 65240 РК. Программа определения глубины залегания подповерхностных объектов методом георадиолокационного зондирования / И.М. Орман, И.Г. Курмашев, К.Т. Исаков; опублик. 01.12.2025.

- 16 Владов М.Л., Старовойтов А.В. Введение в георадиолокацию: учеб. пос. – М., 2004. – 153 с.
- 17 Владов М.Л., Судакова М.С. Георадиолокация: от физических основ до перспективных направлений. – М.: ГЕОС, 2017. – 240 с.
- 18 Воробьев С.Н. Цифровая обработка сигналов. – М.: Академия, 2013. – 320 с.
- 19 Принцип работы георадара «Лоза-В» // <https://moodle.enu.kz/mod/folder/view.php?id=29010>. 10.10.2025.
- 20 Тихонов А.Н., Шахсуваров Д.Н. Метод моделирования ТЭМ-полей в слоистых средах // Известия АН СССР. – 1956. – №3. – С. 251-254.
- 21 Дмитриев В.И. Универсальный метод инверсии электромагнитного поля в слоистых средах // Вычислительные методы и программирование: сб. ст. – М., 1968. – Вып. 10. – С. 55-65.
- 22 Дмитриев В.И., Федорова Е.А., Численное моделирование электромагнитных полей в слоистых средах // Вычислительные методы и программирование: сб. ст. – М., 1980. – Вып. 32. – С. 150-183.
- 23 Гельфанд И.М., Локуцкий О.В., Метод «пробега» для решения разностных уравнений // В кн.: Введение в теорию разностных схем. – М., 1962. – С. 283-309.
- 24 Аккуратов Г.В., Дмитриев В.И., Метод инверсии стационарных упругих волновых полей в слоистых средах // Чистые методы в геофизике: сб. тр. – М., 1979. – С. 3-12.
- 25 Аккуратов Г.В., Дмитриев В.И., 1984. Метод обращения стационарных упругих волновых полей в слоистых средах // Журнал Вычислительной Математики и Математической Физики. – 1984. – Т. 24, №2. – С. 272-286.
- 26 Pavlov V.M. A convenient technique for calculating synthetic seismograms in layered half-space // Proceed. of the internat. conf. “Problems of Geocosmos”. – SPb., 2002. – P. 320-323.
- 27 Fatianov A.G., Mikhailenko B.G. A method for inversion of non-stationary wave fields in non-elastic layered media // Dokl. Akad. Nauk SSSR. – 1988. – Vol. 301, Issue 4. – P. 834-839.
- 28 Fatianov A. G., Semi-analytical solutions to forward dynamic problems for layered media // Dokl. Akad. Nauk SSSR. – 1990. – Vol. 310, Issue 2. – P. 323-327.
- 29 Фатьянов А.Г. Нестационарные сейсмические волновые поля в неоднородных анизотропных средах с поглощением энергии. – Новосибирск. 1989. – 44 с.
- 30 Карчевский А.Л. Метод численного решения системы упругости для горизонтально-слоистой анизотропной среды // Геология и Геофизика. – 2005. – Т. 46, №3. – С. 339-351.
- 31 Карчевский А.Л. Прямая динамическая задача сейсмоки для горизонтально слоистых сред // Сибирские электронные математические известия. – 2005. – №2. – С. 23-61.
- 32 Карчевский А. Л., Аналитическое решение уравнений Максвелла в частотной области для слоистых анизотропных сред // Русская геология и геофизика. – 2007. – Т. 48, №8. – С. 689-695.

- 33 Karchevsky A.L., Rysbayuly B.R. Analytical expressions for a solution of convective heat and moisture transfer equations in the frequency domain for layered media // Eurasian Journal of Mathematical and Computer Applications. – 2015. – Vol. 3, Issue 4. – P. 55-67.
- 34 Karchevsky A.L. Analytical Solutions to the Differential Equation of Transverse Vibrations of a Piecewise Homogeneous Beam in the Frequency Domain for the Boundary Conditions of Various Types // Journal of Applied and Industrial Mathematics. – 2020. – Vol. 14, Issue 4. – P. 52-69.
- 35 Somersalo E., Cheney M., Isaacson D. et al. Layer stripping: a direct numerical method for impedance imaging // Inverse Problems. – 1991. – Vol. 7. – P. 899-926.
- 36 Тихонов А.Н. Сб науч. тр.: в 10 т. – М.: Наука, 2009. – Т. 1, ч. 1. – 636 с.
- 37 Tikhonov A.N., Arsenin V.Y. Methods for solving ill-posed problems. – М.: Nauka, 1979. – 288 p.
- 38 Лаврентьев М.М., Романов В.Г., Васильев В.Г. Многомерные обратные задачи для дифференциальных уравнений. – Новосибирск: Наука, 1969. – 67 с.
- 39 Лаврентьев М.М., Романов В.Г., Шишацкий С.П. Некоторые задачи математической физики и анализа. – М.: Наука, 1980. – 286 с.
- 40 Vasin V.V., Ageev A.L., Ill-posed problems with a priori information. – Ekaterinburg: Nauka, 1995. – 255 p.
- 41 Yagola A.G., Yanfei V., Stepanova I.E. et al. Inverse problems and methods for their solution. Applications in geophysics. – М., 2014. – 216 p.
- 42 Sibiryakov N.E., Kochkin D.Yu., Kabov O.A. et al. Determining the Heat Flux Density in the Area of a Contact Line during the Evaporation of Liquid into a Bubble // Journal of Applied and Industrial Mathematics. – 2023. – Vol. 17, Issue 3. – P. 628-639.
- 43 Belonosov A., Shishlenin M. Regularization Methods of the Continuation Problem for the Parabolic Equation // Proc. 6th internat. conf. Numerical Analysis and Its Applications - (NAA 2016). – Cham, 2016. – P. 220-226.
- 44 Karchevsky A.L. Reformulation of an inverse problem statement that reduces computational costs // Eurasian Journal of Mathematical and Computer Applications. – 2013. – Vol. 1, Issue 2. – P. 4-20.
- 45 Karchevsky A.L., Marchuk I.V., Kabov O.A. Calculation of the heat flux near the liquid-gas-solid contact line // Applied Mathematical Modelling. – 2016. – Vol. 40, Issue 2. – P. 1029-1037.
- 46 Cheverda V.V., Marchuk I.V., Karchevsky A.L. et al. Experimental investigation of heat transfer in a rivulet on the inclined foil // Thermophysics and Aeromechanics. – 2016. – Vol. 23, Issue 3. – P. 415-420.
- 47 Cheverda V.V., Karchevsky A.L., Marchuk I.V. et al. Heat flux density in the region of droplet contact line on a horizontal surface of a thin heated foil // Thermophysics and Aeromechanics. – 2017. – Vol. 24, Issue 5. – P. 803-806.
- 48 Karchevsky A.L. Numerical solving the heat equation with data on a time-like boundary for the heated thin foil technique // Eurasian Journal of Mathematical and Computer Application. – 2020. – Vol. 8, Issue 4. – P. 4-14.

- 49 Yaparova N.M. On various approaches to solving inverse boundary value problems of thermal diagnostics // Vestn. SUSU. – 2012. – Vol. 7. – P. 60-67.
- 50 Yaparova N.M. Numerical modeling of solutions to the inverse boundary value problem of heat conduction // Vestn. SUSU. – 2013. – Vol. 6. – P. 112-124.
- 51 Di Graziano A., Marchetta V., Cafiso S. Structural health monitoring of asphalt pavements using smart sensor networks: A comprehensive review // Journal of Traffic and Transportation Engineering. – 2020. – Vol. 7, Issue 5. – P. 639-651.
- 52 Khan S.M. et al. Integration of structural health monitoring and intelligent transportation systems for bridge condition assessment: Current status and future direction // IEEE Transactions on Intelligent Transportation Systems. – 2016. – Vol. 17, Issue 8. – P. 2107-2122.
- 53 Mudabir M., Mosavi A., Imre F. et al. Modeling Remaining Service Life and Structural Health Monitoring of Roads with Machine Learning and Deep Learning // Proc. IEEE 23rd World sympos. on Applied Machine Intelligence and Informatics (SAMI). – Stará Lesná, 2025. – P. 000413-000422.
- 54 Ramadan S., Kassem H., ElKordi A. et al. Incorporating artificial intelligence applications in flexible pavements: A comprehensive overview // International Journal of Pavement Research and Technology. – 2024. – Vol. 19. – P. 902-927.
- 55 Setyawan A., Nainggolan J., Budiarto A. Predicting the remaining service life of road using pavement condition index // Procedia Engineering. – 2015. – Vol. 125. – P. 417-423.
- 56 Kodikara J., Sountharajah A., Chen L. Reimagining unbound road pavement technology: Integrating testing, design, construction and performance in the post-digital era // Transportation Geotechnics. – 2024. – Vol. 47. – P. 101274.
- 57 Olugbade S. et al. A review of artificial intelligence and machine learning for incident detectors in road transport systems // Mathematical and Computational Applications. – 2022. – Vol. 27, Issue 5. – P. 77.
- 58 Jagatheesaperumal S.K. et al. Artificial Intelligence for road quality assessment in smart cities: a machine learning approach to acoustic data analysis // Computational Urban Science. – 2023. – Vol. 3, Issue 1. – P. 28.
- 59 Goumiri S., Yahiaoui S., Djahel S. Smart Mobility in Smart Cities: Emerging challenges, recent advances and future directions // Journal of Intelligent Transportation Systems. – 2025. – Vol. 29, Issue 1. – P. 81-117.
- 60 Akhayeva Z., Zakirova A., Zhmud V. Optimization of water resources management using big data and machine learning in smart cities // Eurasian Journal of Mathematical and Computer Applications. – 2024. – Vol. 12, Issue 2. – P. 4-15.
- 61 Gharehbaghi V.R. et al. A critical review on structural health monitoring: Definitions, methods, and perspectives // Archives of computational methods in engineering. – 2022. – Vol. 29, Issue 4. – P. 2209-2235.
- 62 Fawad M. et al. Automation of structural health monitoring (SHM) system of a bridge using Bimification approach and BIM-based finite element model development // Scientific Reports. – 2023. – Vol. 13, Issue 1. – P. 13215.
- 63 Zhang H. et al. Static and ultrasonic structural health monitoring of full-size aerospace multi-function capsule using FBG strain arrays and PSFBG acoustic emission sensors // Optical Fiber Technology. – 2023. – Vol. 78. – P. 103316.

- 64 Saidin S.S. et al. An overview: The application of vibration-based techniques in bridge structural health monitoring // *International Journal of Concrete Structures and Materials*. – 2022. – Vol. 16, Issue 1. – P. 69.
- 65 Bernard A., Yakovenko S. Application of machine learning methods to channel flow modelling // *Eurasian Journal of Mathematical and Computer Applications*. – 2025. – Vol. 13, Issue 2. – P. 4-12.
- 66 Ramzan B., Malik M.S., Martarelli M. et al. Pixel frequency based railroad surface flaw detection using active infrared thermography for structural health monitoring // *Case Studies in Thermal Engineering*. – 2021. – Vol. 27. – P. 101234.
- 67 Jiang X. et al. Evaluation of inverted pavement by structural condition indicators from falling weight deflectometer // *Construction and Building Materials*. – 2022. – Vol. 319. – P. 125991
- 68 Kulkarni N.N., Raisi K., Valente N.A. et al. Deep learning augmented infrared thermography for unmanned aerial vehicles structural health monitoring of roadways // *Automation in Construction*. – 2023. – Vol. 148. – P. 104784.
- 69 Flah M. et al. Machine Learning Algorithms in Civil Structural Health Monitoring: A Systematic Review // *Archives of computational methods in engineering*. – 2021. – Vol. 28, Issue 4. – P. 2621-2643/
- 70 Elghaish F. et al. (2022). Deep learning for detecting distresses in buildings and pavements: a critical gap analysis // *Construction Innovation*. – 2022. – Vol. 22, Issue 3. – P. 554-579.
- 71 Plevris V., Papazafeiropoulos G. AI in structural health monitoring for infrastructure maintenance and safety // *Infrastructures*. – 2024. – Vol. 9, Issue 12. – P. 225.
- 72 Alnaqbi A. et al. A hybrid approach of support vector regression with genetic algorithm optimization for predicting spalling in continuously reinforced concrete pavement // *J of Building Pathology and Rehabilitation*. – 2024. – Vol. 9, Issue 2. – P. 146.
- 73 Xin J., Akiyama M., Frangopol D.M. et al. Reliability-based life-cycle cost design of asphalt pavement using artificial neural networks // *Structure and Infrastructure Engineering*. – 2021. – Vol. 17, Issue 6. – P. 872-886.
- 74 Ali A.A., Milad A., Hussein A. et al. Predicting pavement condition index based on the utilization of machine learning techniques: A case study // *Journal of Road Engineering*. – 2023. – Vol. 3, Issue 3. – P. 266-278.
- 75 Zhao K., Xu S., Loney J. et al. Road pavement health monitoring system using smartphone sensing with a two-stage machine learning mode // *Automation in Construction*. – 2024. – Vol. 167. – P. 105664.
- 76 Cao Q., Al-Qadi I.L., Abufares L. Pavement moisture content prediction: A deep residual neural network approach for analyzing ground penetrating radar // *IEEE Transactions on Geoscience and Remote Sensing*. – 2022. – Vol. 60. – P. 1-11.
- 77 Roberts R., Inzerillo L., Di Mino G. Exploiting data analytics and deep learning systems to support pavement maintenance decisions // *Applied Sciences*. – 2021. – Vol. 11, Issue 6. – P. 2458.

78 Kang J. et al. Artificial intelligence techniques for pavement performance prediction: a systematic review // *Road Materials and Pavement Design*. – 2025. – Vol. 26, Issue 3. – P. 497-522.

79 Zhang H., Liu T., Lu J. et al. Static and ultrasonic structural health monitoring of full-size aerospace multi-function capsule using FBG strain arrays and PSFBG acoustic emission sensors // *Optical Fiber Technology*. – 2023. – Vol. 78. – P. 103316.

80 Chen K., Torbaghan M.E., Thom N. et al. A Machine Learning based approach to predict road rutting considering uncertainty // *Case Studies in Construction Materials*. – 2024. – Vol. 20. – P. e03186.

81 Elghaish F. et al. Multi-layers deep learning model with feature selection for automated detection and classification of highway pavement cracks // *Smart and Sustainable Built Environment*. – 2025. – Vol. 14, Issue 2. – P. 511-535.

82 Baduge S.K., Thilakarathna S., Perera J.S. et al. Assessment of crack severity of asphalt pavements using deep learning algorithms and geospatial system // *Construction and Building Materials*. – 2023. – Vol. 401. – P. 132684.

83 Doroudi R., Lavassani S.H.H., Shahrouzi M. Optimal tuning of three deep learning methods with signal processing and anomaly detection for multi-class damage detection of a large-scale bridge // *Structural Health Monitoring*. – 2024. – Vol. 23, Issue 5. – P. 3227-3252.

84 Cano-Ortiz S., Pascual-Muñoz P., Castro-Fresno D. Machine learning algorithms for monitoring pavement performance // *Automation in Construction*. – 2022. – Vol. 139. – P. 104309.

85 Sedighian-Fard M. et al. Data generation for asphalt pavement evaluation: Deep learning-based insights from generative models // *Case Studies in Construction Materials*. – 2025. – Vol. 23. – P. e05116.

86 Ebika I.M., Idoko D.O., Efe F. et al. Utilizing machine learning for predictive maintenance of climate-resilient highways through integration of advanced asphalt binders and permeable pavement systems with IoT technology // *International J of Innovative Science and Research Technology*. – 2024. – Vol. 9, Issue 11. – P. 69-89.

87 Tamagusko T. et al. Machine Learning Applications in Road Pavement Management: A Review // *Challenges and Future Directions. Infrastructures*. – 2024. – Vol. 9, Issue 12. – P. 213.

88 Yao L., Leng Z., Jiang J. et al. Modelling of pavement performance evolution considering uncertainty and interpretability: a machine learning based framework // *International J of Pavement Engineering*. – 2022. – Vol. 23, Issue 14. – P. 5211-5226.

89 Omar I. Machine learning (ml) approaches to model interdependencies between dynamic loads and crack propagation Cranfield University // <https://dspace.lib.cranfield.ac.uk/handle/1826/24026>. 10.10.2025.

90 Ahmad F., Alasskar A., Samui P. et al. Machine learning-based graphical user interface for predicting high-performance concrete compressive strength: comparative analysis of gradient boosting machine, random forest, and deep neural network models // *Frontiers of Structural and Civil Engineering*. – 2025. – Vol. 19, Issue 7. – P. 1075-1090.

91 Alatoom Y.I., Al-Suleiman T.I. Development of pavement roughness models using Artificial Neural Network (ANN) // *International Journal of Pavement*

Engineering. – 2022. – Vol. 23, Issue 13. – P. 4622-4637.

92 Gooda S.K., Chinthamu N., Selvan S.T. et al. Automatic detection of road cracks using efficientnet with residual u-net-based segmentation and yolov5-based detection // Int. J. Recent Innov. Trends Comput. Commun. – 2023. – Vol. 11, Issue 4. – P. 84-91.

93 Mers M., Yang Z., Hsieh Y.-A. et al. Recurrent neural networks for pavement performance forecasting: review and model performance comparison // Transportation Research Record. – 2023. – Vol. 2677, Issue 1. – P. 610-624.

94 Ngoc-Mai N., Cao M.T. Predicting Mechanical Properties of Concrete Structures Using Metaheuristic Optimization-Based Machine Learning Models // <https://ssrn.com/abstract=4923416>. 10.10.2025.

95 Nouredine S., Zineedine B., Toumi A. et al. A new predictive medical approach based on data mining and Symbiotic Organisms Search algorithm // International Journal of Computers and Applications. – 2022. – Vol. 44, Issue 5. – P. 465-479.

96 Stöhr H., Hennings E. Deep Learning for Pavement Distress Forecasting: A Hybrid-LSTM Approach and Application Evaluation for Efficient Pavement Maintenance Forecasting // <https://www.diva-portal.org>. 10.10.2025.

97 Alaloul W.S., Altaf M., Musarat M.A. et al. Systematic review of life cycle assessment and life cycle cost analysis for pavement and a case study // Sustainability. – 2021. – Vol. 13, Issue 8. – P. 4377.

98 Benkhalfallah M.S., Kouah S., Harous S. Predicting the Energy Consumption in Chillers: A Comparative Study of Supervised Machine Learning Regression Models // Energies. – 2025. – Vol. 18, Issue 14. – P. 3672.

99 Карчевский А.Л. Одновременная реконструкция диэлектрической проницаемости и проводимости // Journal of Inverse and Ill-Posed Problems. – 2009. – Vol. 17, Issue 4. – P. 385-402.

100 Романов В.Г., Карчевский А.Л. Определение диэлектрической проницаемости и проводимости среды в окрестности скважины со сложным профилем. // Eurasian Journal of Mathematical and Computer Applications. – 2018. – Vol. 6, Issue 4. – P. 64-74.

101 Градштейн И.С., Рыжик И.М. Таблицы интегралов, сумм, рядов и произведений. – М., 1962. – 1108 с.

102 Янке Э., Эмде Ф., Лёш Ф. Таблицы высших функций. – Штутгарт, 1960. – 340 с.

103 Котельников В.А. О пропускной способности «эфира» и провода в электрических коммуникациях. // Успехи физических наук. – 2006. – Т. 49. – С. 736-744.

104 Nyquist H. Certain Topics in Telegraph Transmission Theory // Transactions of the American Institute of Electrical Engineers – 1928. – Vol. 47, Issue 2. – P. 617-644.

105 Васильев Ф.П. Численные методы решения экстремальных задач. – М.: Наука, 1988. – 552 с.

106 Карчевский А.Л. Численное решение одномерной обратной задачи для упругой системы // Докл. РАН. – 2000. – Т. 375, №8. – С. 325-328.

107 Карчевский А.Л. Определение возможности горного удара в угольном пласте // Journal of Applied and Industrial Mathematics. – 2017. – Vol. 11, Issue 4. – P. 527-534.

108 Karchevsky A.L., Dedok V.A. Reconstruction of Permittivity from the Modulus of a Scattered Electric Field // Journal of Applied and Industrial Mathematics. – 2018. – Vol. 12, Issue 3. – C. 470-478.

# ПРИЛОЖЕНИЕ А

## Свидетельство об авторском праве

ҚАЗАҚСТАН РЕСПУБЛИКАСЫ  РЕСПУБЛИКА КАЗАХСТАН

**СВИДЕТЕЛЬСТВО**  
**О ВНЕСЕНИИ СВЕДЕНИЙ В ГОСУДАРСТВЕННЫЙ РЕЕСТР**  
**ПРАВ НА ОБЪЕКТЫ, ОХРАНЯЕМЫЕ АВТОРСКИМ ПРАВОМ**

№ 65240 от «11» декабря 2025 года

Фамилия, имя, отчество (если оно указано в документе, удостоверяющем личность) автора (ов):  
**ОРМАН ИНДИРА МӨЛІКҚЫЗЫ,** Курманшев Ильядар Гусмамонович,  
**Искаков Казизат Такуадильевна**

Вид объекта авторского права: программа для ЭВМ

Название объекта: Программа определения глубины залегания подповерхностных объектов методом георадиолокационного зондирования

Дата создания объекта: 01.12.2025



Агент интеллектуальных прав  
"Авторские права" Белаяозар тасарулы болшы <https://copyright.kazakhstan.kz>

Подлинность документа возможно проверить на сайте [copyright.kz](https://copyright.kazakhstan.kz)  
и разделе «Авторское право» <https://copyright.kazakhstan.kz>

Подписано ЭЦП 

С. Ахметов

## ПРИЛОЖЕНИЕ Б

### Акты внедрения

УТВЕРЖДАЮ  
Декан школы архитектуры,  
строительства и энергетики  
НАО ВКТУ имени Д. Серикбаева  
А.М. Акаев  
2026 г.



#### АКТ ВНЕДРЕНИЯ (ИСПОЛЬЗОВАНИЯ)

результатов научно-исследовательской работы, выполненной в рамках  
диссертационной работы, PhD докторанта  
Северо-Казахстанского университета им. М.Козыбаева  
Орман Индиры Маликовны  
в учебный процесс

Мы, нижеподписавшиеся, Айтказина А.К. руководитель образовательной программы «6807115 - Проектирование и строительство автомобильных дорог», старший преподаватель школы архитектуры, строительства и дизайна; Искаков К.Т. - доктор физико-математических наук, профессор Евразийского национального университета имени Л.Н. Гумилева, научный консультант внедряемых результатов, составили настоящий АКТ ВНЕДРЕНИЯ (ИСПОЛЬЗОВАНИЯ) результатов научно-исследовательской работы, выполненной докторантом Орман И.М. в рамках диссертационной работы на тему: «Разработка алгоритмов и программного обеспечения для определения электромагнитных параметров включения в подстилающей среде».

#### Область применения

Программа применяется в георадиолокационных исследованиях геофизики, георазведке, контроле автодорожных покрытий и строительных площадок, а также в учебном процессе для студентов и магистрантов, обучающихся по специальностям «Геофизические технологии и инжиниринг» и «Вычислительная техника и программное обеспечение» ВУЗов.

#### Назначение

Программа предназначена для первичной обработки георадарных данных и визуализации георадиолокационной информации, что облегчает интерпретацию радарограммы в георадиолокационных исследованиях. Программа спектрального анализа и вейвлет очистки трасс радарограмм дополняет и улучшает интерпретацию результатов георадарных исследований с помощью фирменных ПО, поставляемых вместе с георадарами.

#### Функциональные возможности

1. Ввод данных из файла радарограммы;
2. График трасс радарограммы;
3. График спектра трасс радарограммы;
4. Вейвлет очистка цифровых сигналов трасс радарограммы.
5. График спектра очищенной трассы радарограммы;
6. Определяет глубину залегания объекта;

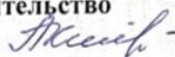
7. Вычисление диэлектрической проницаемости и электрической проводимости подповерхностной среды.

8. Сохранение графиков в формате jpeg.

Использование программного продукта в учебном процессе в рамках лекционных и практических занятий по дисциплинам образовательной программы «6В07115 - Проектирование и строительство автомобильных дорог» дополняет содержание дисциплин знаниями и навыками работы с вычислительными системами обработки данных георадара.

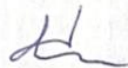
Прилагается авторское свидетельство (№65240 от 11.12.2025) на программный продукт.

Руководитель образовательной программы  
«6В07115 - Проектирование и строительство  
автомобильных дорог»



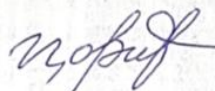
А.К. Айтказина

Научный консультант



К.Т. Исаков

Докторант



И.М. Орман

# Акты внедрения

## АКТ о внедрении программного продукта

г. Астана  
«20» декабря 2025 года

Настоящий акт подтверждает, что программный продукт для ЭВМ «Программа обработки и интерпретации георадиолокационных данных для мониторинга и диагностики подповерхностных слоёв на основе алгоритмов глубокого обучения», разработанный Орман И.М., Исаковым К.Т., Мосави А., создан в рамках диссертационной работы Орман Индиры Маликовны на тему: «Разработка алгоритмов и программного обеспечения для определения электромагнитных параметров включения в подстилающей среде», результаты которой легли в основу разработанного программного продукта, реализующего алгоритмы обработки, анализа и интерпретации георадиолокационных данных, внедрен в деятельность РГП на ПХВ «Национальный центр качества дорожных активов».

*Область применения:* Программный продукт применяется при проведении георадиолокационных исследований автомобильных дорог.

Программа используется для выявления дефектов в подповерхностной среде, включая дорожные одежды, с применением современных методов анализа данных, включая Deep Learning.

*Назначение программного продукта:* Программный продукт для выявления дефектов в подповерхностной среде, включая дорожные одежды, с применением современных методов анализа данных, получаемых с использованием георада «ОКО - 2».

В рамках программного продукта реализованы методы глубокого обучения, обеспечивающие автоматическое выявление скрытых закономерностей в георадиолокационных данных и повышение достоверности результатов интерпретации.

В ходе эксплуатации подтверждено, что разработанный программный продукт соответствует заявленным функциональным характеристикам и может быть рекомендована для первоначальной диагностики транспортной инфраструктуры.

Представители РГП на ПХВ «Национальный центр качества дорожных активов».

Директор департамента диагностики  
и ведомственной экспертизы



Т.А. Жусупов

Главный эксперт отдела диагностики  
и мониторинга безопасности  
дорожной инфраструктуры

К. К. Калменов

## ПРИЛОЖЕНИЕ В

### Результат обработки в программе «Крот»

1 шаг: Открываем файл «39-зондирование 50 см антенной шаг 20 см» (рисунок В.1)

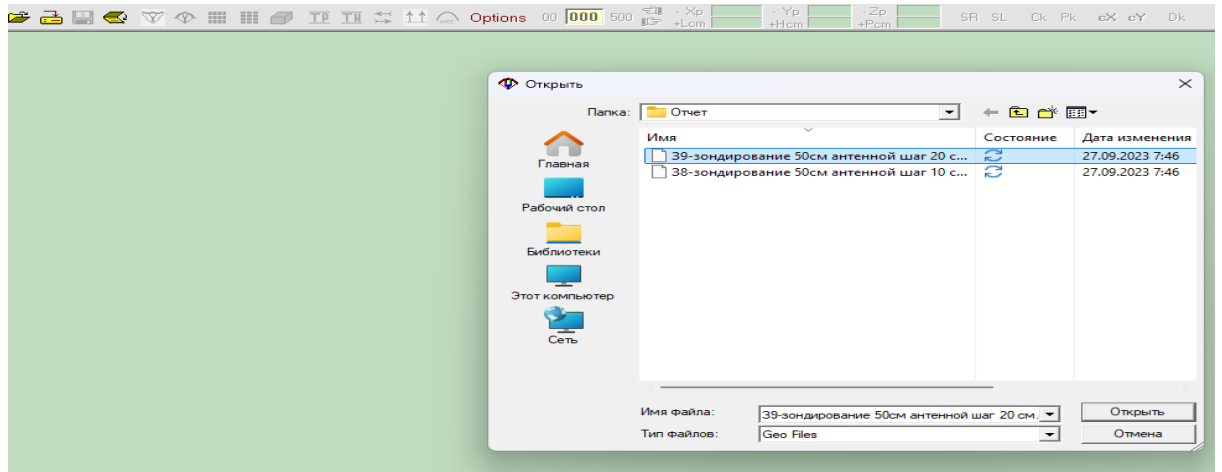


Рисунок В.1 - файл «39-зондирование 50 см антенной шаг 20 см»

1 Шаг. Растягиваем радарограмму по горизонтали (рисунок В.2).

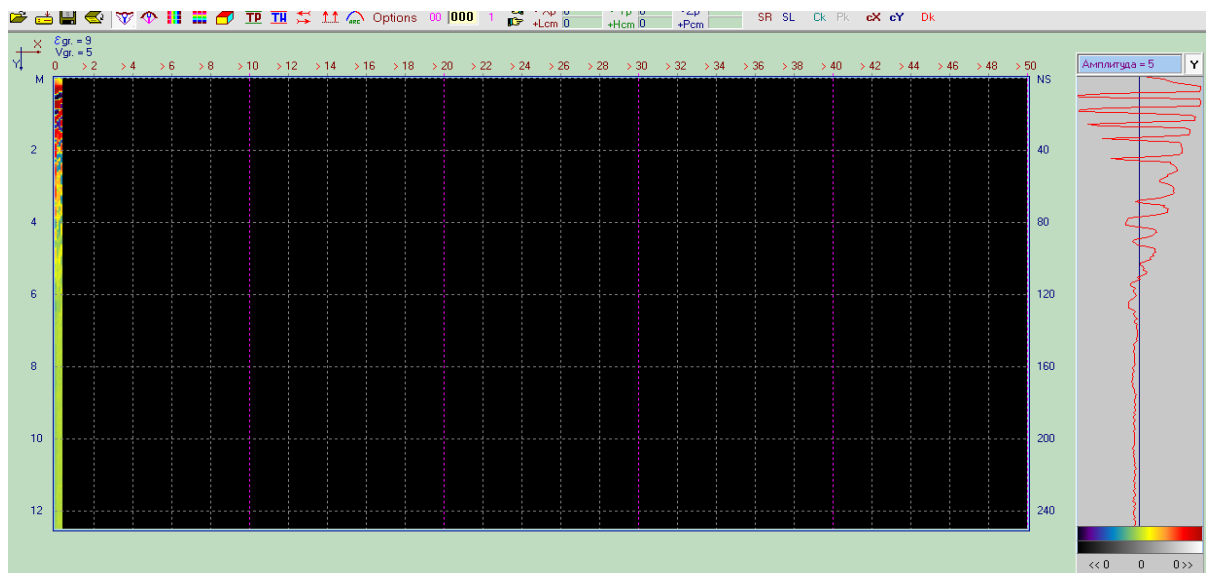


Рисунок В.2 - Радарограмму по горизонтали

### 3 Шаг. Настройка профиля (рисунок В.3).




Рисунок В.3 - Настройка профиля

### 4 Шаг. Настраиваем фильтры (рисунок В.4).




Рисунок В.4 - Настраиваем фильтры

Фильтр 1 НЧ2 - низкочастотный реверсивный, хорошо сглаживает шум, сохраняя границы (рисунок В.5).

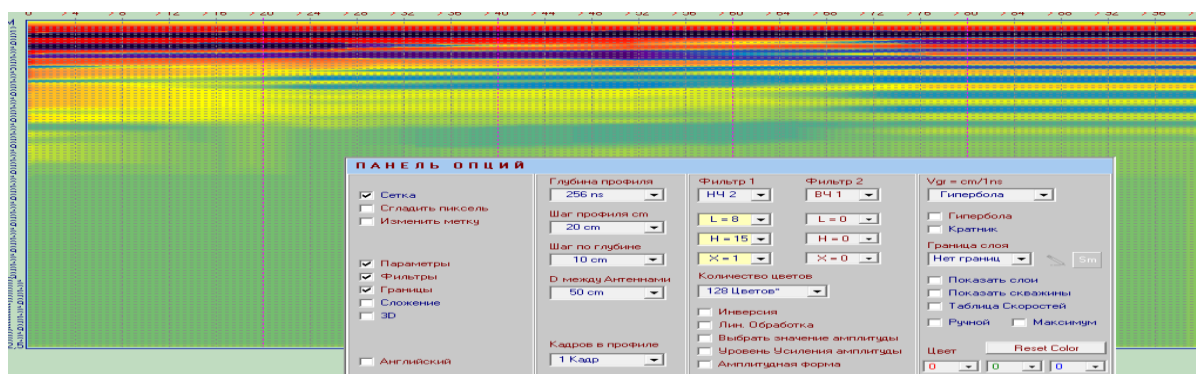


Рисунок В.5 - Фильтр 1 НЧ2 - низкочастотный реверсивный, хорошо сглаживает шум, сохраняя границы

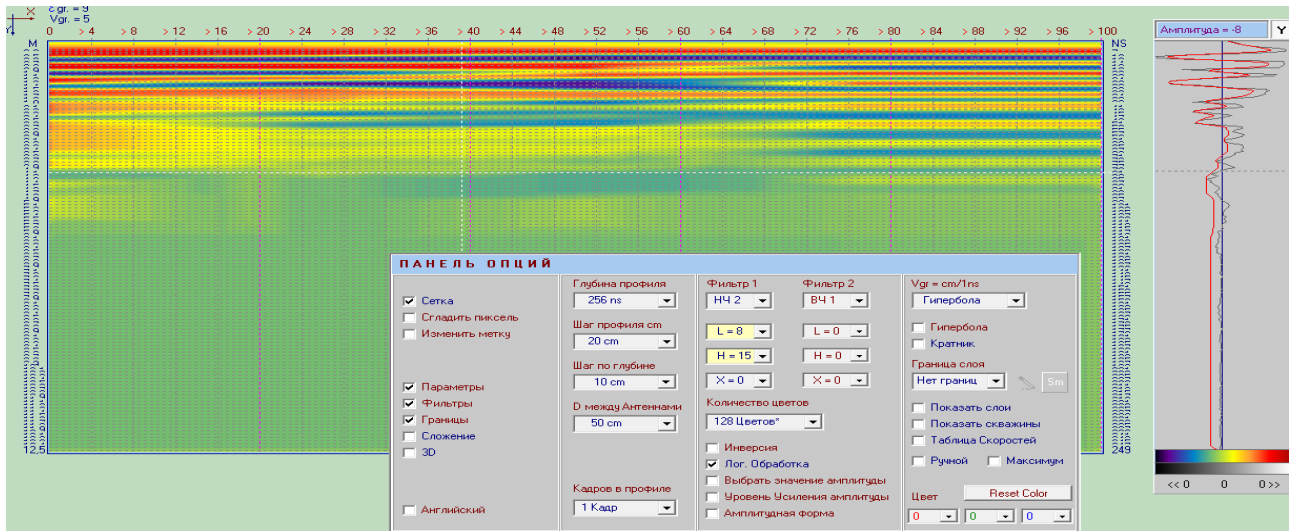


Рисунок В.6 - ВЧ-фильтр подчёркивает резкие изменения (трубы, камни, пустоты, гиперболы) - отлично для поиска объектов.

5 Шаг. Определение диэлектрической проницаемости, при помощи гиперболы (рисунок В.7).




Рисунок В.7 - Определение диэлектрической проницаемости, при помощи гиперболы




Рисунок В.8 - Радарограмме горизонтальную границу

6 Шаг. Разметка слоев (рисунок В.9).



Рисунок В. 9 - Разметка слоев

Из выпадающего списка выбираем слой, устанавливаем автоматическую разметку и функцию притяжения «Максимум/Минимум» (рисунок В.10).

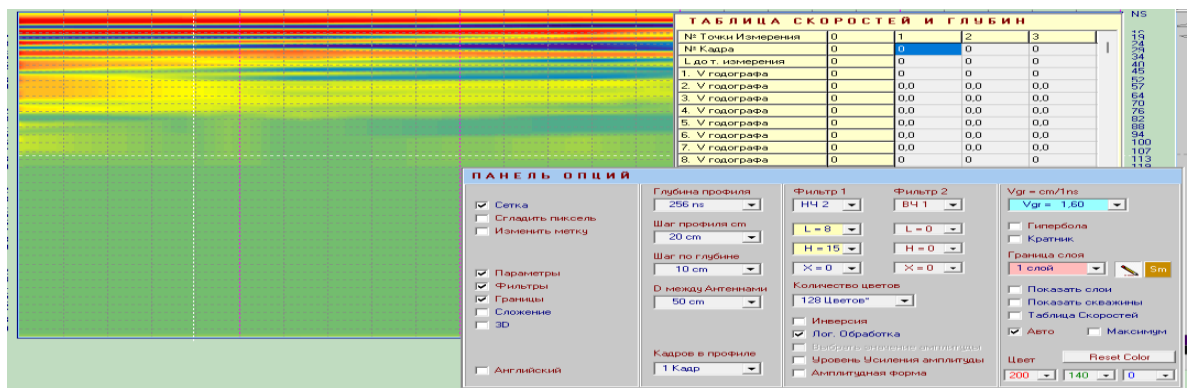


Рисунок В.10 - Устанавливаем автоматическую разметку и функцию притяжения «Максимум/Минимум»

Выбираем карандаш и протягиваем по радиограмме, автонастройка подтянет на нужный уровень (рисунок В.11).

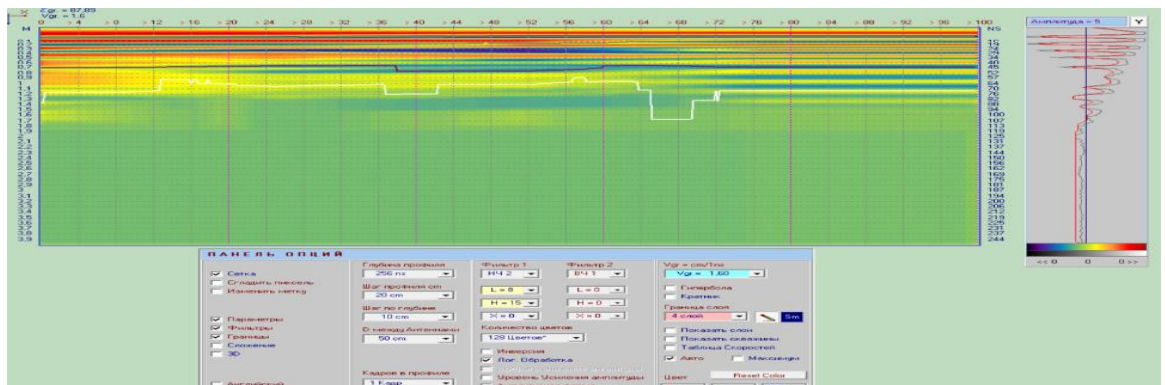



Рисунок В.11 - Автонастройка подтянет на нужный уровень

Сохраняем (рисунок В.12)



Рисунок В.12 - Сохраняем

## ПРИЛОЖЕНИЕ Д



а

	A	B	C	D	E	F	G	H
28	9	8,5	25,0247	9,3202	7,518	6,94794	7,26833	8,48048
29	9	14,5	26,0464	13,4047	8,7602	8,64184	12,99	8,76727
30	9	11,5	26,6904	11,9695	13,0647	10,9273	11,4045	7,99285
31	9	19	26,2923	12,6338	11,6709	12,2765	12,0346	11,4393
32	9	19	26,7524	7,17072	11,1245	8,98731	14,183	7,80324
33	9	6,5	25,7585	9,13246	10,8402	12,4909	10,3067	8,83342
34	9	5,5	25,0873	7,76231	8,83206	9,13001	9,08333	8,50118
35	8	8,5	25,1229	7,77244	8,7691	8,10913	7,26833	7,07225
36	8	8	25,8157	13,2802	8,40208	7,30473	8,37222	6,77432
37	8	7,5	26,2891	7,76424	8,77685	7,33214	5,90595	6,46548
38	8	4,5	25,1715	6,87691	7,54636	3,02573	6,42024	7,44119
39	8	9	27,7068	8,43931	9,66103	8,01824	11	6,45677
40	7	7,5	25,5678	6,25591	6,53923	6,8607	4,76333	6,03579
41	7	12,5	26,2316	8,76945	6,0078	8,47345	10,2917	7,03482
42	7	7,5	25,7461	4,17128	6,45858	5,03749	7,5875	7,83744
43	7	4,5	25,265	2,75245	7,03102	6,44465	5,39952	5,41603
44	7	5,5	25,875	6,67356	1,45564	5,69881	4,80167	8,25301
45	7	5	26,9331	10,3121	6,86899	5,32422	13,5771	5,59269
46	6	6,5	25,5688	6,67757	5,29519	3,57539	6,72937	4,97914
47	6	13	26,0868	5,89719	10,0854	5,82715	8,95333	14,3556

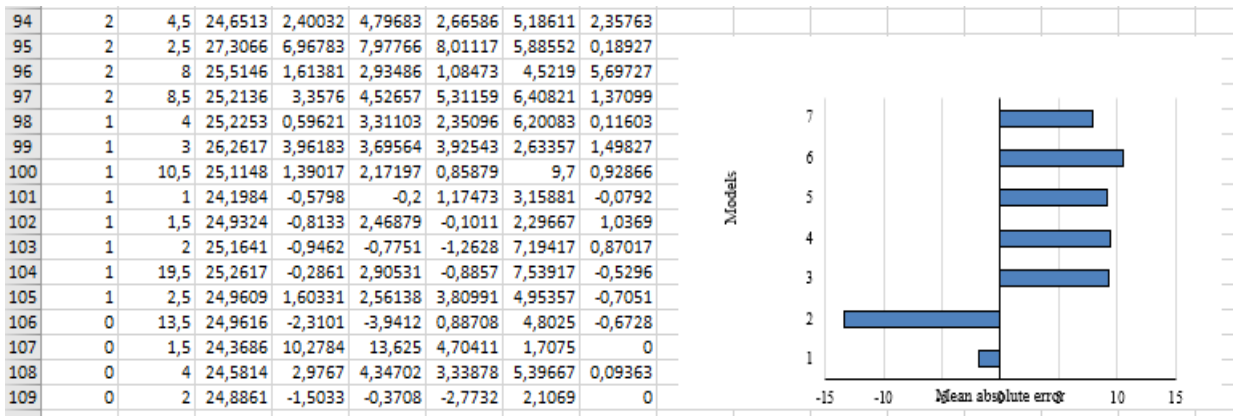
б

Рисунок Г.1 – Обработка точечных данных и построение модели по этим данным в программе MATLAB, лист 1

47	6	13	26,0868	5,89719	10,0854	5,82715	8,95333	14,3556
48	6	5,5	26,6135	7,59787	5,91704	6,66904	10,1024	4,66122
49	6	10,5	25,176	6,48184	6,11409	7,56434	12,9012	4,74203
50	6	10,5	26,2483	6,17231	3,56743	6,2831	10,8143	5,61175
51	6	7	26,9803	6,57491	8,24097	5,43488	8,55595	5,16685
52	5	5,5	25,9906	0,2967	1,57361	6,26257	4,46687	3,89335
53	5	9,5	24,9587	7,63593	6,18079	6,21619	7,15389	2,99052
54	5	3,5	25,529	4,23294	2,39537	4,22922	6,03571	3,68255
55	5	12	26,8072	5,34716	7,60006	7,08497	12,8411	4,25444
56	4	4,5	25,4392	2,39355	8,69455	3,09227	3,96964	2,37338
57	4	8,5	25,3044	3,84515	4,68436	4,91292	8,98929	3,59059
58	4	5	27,8312	6,45006	4,96988	5,77655	3,95857	4,1116
59	4	10	25,7891	7,63173	6,41062	2,87365	4,76131	3,3644
60	4	6,5	26,2249	7,22922	3,73207	3,36642	12,9225	4,34511
61	4	3	25,2685	3,66655	4,04947	3,65982	8,61806	3,67285
62	4	2,5	24,9101	5,82884	5,57939	3,26774	6,08881	4,18647
63	4	3	24,746	5,33087	2,08059	3,18627	4,21167	3,07691
64	4	3	25,9753	3,65193	7,18588	3,3087	5,91167	3,01456
65	4	3,5	25,1454	7,11768	7,15423	10,2125	5,98095	3,57402
66	4	4	24,254	4,69162	3,46745	3,02655	3,54143	3,33357
67	4	4	25,019	1,61431	6,44081	3,92563	5,24849	1,58317
68	4	5,5	24,4879	5,23823	2,76813	3,63271	5,74524	2,29878
69	4	2	25,1826	3,34635	3,71351	3,16058	2,12083	2,48828
70	4	9,5	26,0929	6,27214	6,79691	4,84888	8,41917	3,07706
71	4	3	25,327	5,89905	4,55808	7,14659	7,30663	2,05636
72	4	4	24,2166	3,82295	5,41908	4,27865	3,54143	3,85671
73	3	2,5	25,0852	-1,0267	5,23318	0,36693	4,62167	1,70749
74	3	13	25,7728	2,33367	2,26792	3,08393	16,3536	1,56129
75	3	4,5	25,6433	5,16237	5,31535	1,85341	6,24722	1,26414
76	3	2,5	24,7774	2,9102	-0,6181	5,42842	5,09254	1,22646
77	3	4	25,01	4,42701	4,65863	6,85774	5,94139	4,34527
78	3	3,5	26,777	2,88523	1,30475	3,9193	5,99959	2,25258
79	3	13,5	26,0214	5,84438	2,42046	1,16966	6,86	1,54626
80	3	16,5	25,4324	3,50639	10,0976	5,22144	7,30278	1,60281
81	3	6,5	26,6555	9,29358	9,00166	4,62013	4,21524	2,48881
82	3	2,5	25,9788	4,78323	-0,2613	1,14482	6,87889	2,0916
83	2	2,5	25,6049	3,81506	8,56985	8,03892	6,0025	0,79411
84	2	3,5	24,9399	1,50612	-1,1296	3,20987	3,12837	3,02144
85	2	5,5	25,4647	4,62108	0,29027	5,49029	3,59206	4,39135
86	2	11,5	25,4757	1,99182	1,0947	1,24606	8,30476	0,99769
87	2	5	24,6487	1,46883	4,23054	2,14638	5,42798	1,21455
88	2	1,5	26,0661	4,87373	5,44734	5,02966	2,57857	1,63208
89	2	5,5	24,9254	1,52886	0,87419	2,44328	6,23048	0,91413
90	2	1,5	24,6464	3,62857	4,38181	5,03157	3,36328	0,35286
91	2	7	25,3943	3,90252	-1,1679	4,07727	4,3504	1,55541
92	2	3	25,1748	3,90305	3,89451	1,94274	8,10214	0,89012
93	2	6	24,3954	3,7633	2,95183	1,66653	2,41607	1,27322

В

Рисунок Г.1, лист 2



Г

Рисунок Г.1, лист 3