

Министерство науки и высшего образования Российской Федерации  
 федеральное государственное автономное  
 образовательное учреждение высшего образования  
 «Национальный исследовательский Томский политехнический университет» (ТПУ)

Школа Инженерная школа ядерных технологий  
 Направление подготовки 01.04.02 Прикладная математика и информатика  
 Отделение школы (НОЦ) Отделение экспериментальной физики

### МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ

Тема работы
<b>Применение нейронных сетей для распознавания распределений интенсивности лазерных пучков, обладающих различными значениями орбитального углового момента и распространяющихся через турбулентную атмосферу</b>

УДК 004.93'1:004.032.26:621.373.826

Студент

Группа	ФИО	Подпись	Дата
ОВМ02	Богач Егор Андреевич		

Руководитель ВКР

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор ОИТ ИШИТР ТПУ	Гергет Ольга Михайловна	д.т.н.		

Консультант

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Зам. директора по научной работе ИОА СО РАН	Дудоров Вадим Витальевич	д.ф.-м.н.		

### КОНСУЛЬТАНТЫ ПО РАЗДЕЛАМ:

По разделу «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение»

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОСГН ШБИП ТПУ	Рыжакина Татьяна Гавриловна	к.э.н.		

По разделу «Социальная ответственность»

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор ООД ШБИП ТПУ	Федорчук Юрий Митрофанович	д.т.н.		

### ДОПУСТИТЬ К ЗАЩИТЕ:

Руководитель ООП	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОЭФ ИЯТШ	Семенов Михаил Евгеньевич	к.ф.-м.н.		

Томск – 2022 г.

## ПЛАНИРУЕМЫЕ РЕЗУЛЬТАТЫ ОСВОЕНИЯ ООП

Код компетенции	Наименование компетенции
<b>Универсальные компетенции</b>	
УК(У)-1	Способен осуществлять критический анализ проблемных ситуаций на основе системного подхода, вырабатывать стратегию действий
УК(У)-2	Способен управлять проектом на всех этапах его жизненного цикла
УК(У)-3	Способен организовать и руководить работой команды, вырабатывая командную стратегию для достижения поставленной цели.
УК(У)-4	Способен применять современные коммуникативные технологии, в том числе на иностранном (-ых) языке (-ах), для академического и профессионального взаимодействия.
УК(У)-5	Способен анализировать и учитывать разнообразие культур в процессе межкультурного взаимодействия.
УК(У)-6	Способен определить и реализовать приоритеты собственной деятельности и способы ее совершенствования на основе самооценки.
<b>Общепрофессиональные компетенции</b>	
ОПК(У)-1	Способен решать актуальные задачи фундаментальной и прикладной математики
ОПК(У)-2	Способен совершенствовать и реализовывать новые математические методы решения прикладных задач
ОПК(У)-3	Способен разрабатывать математические модели и проводить их анализ при решении задач в области профессиональной деятельности
ОПК(У)-4	Способен комбинировать и адаптировать существующие информационно-коммуникационные технологии для решения задач в области профессиональной деятельности с учетом требований информационной безопасности
<b>Профессиональные компетенции</b>	
ПК(У)-1	Способен проводить научные исследования и получать новые научные и прикладные результаты самостоятельно и в составе научного коллектива
ПК(У)-2	Способен проводить поиск и анализ научной и научно-технической литературы по тематике проводимых исследований
ПК(У)-3	Способен разрабатывать и анализировать показатели качества информационных систем, используемых в производственной деятельности
ПК(У)-4	Способен планировать научно-исследовательскую деятельность, анализировать риски, управлять проектами, управлять командой проекта
ПК(У)-5	Способен преподавать математических дисциплин и информатики в образовательных организациях высшего образования
ПК(У)-6	Способен проектировать и организовывать учебный процесс по образовательным программам с использованием современных образовательных технологий



<p><b>Перечень подлежащих исследованию, проектированию и разработке вопросов</b>  <i>(аналитический обзор по литературным источникам с целью выяснения достижений мировой науки техники в рассматриваемой области; постановка задачи исследования, проектирования, конструирования; содержание процедуры исследования, проектирования, конструирования; обсуждение результатов выполненной работы; наименование дополнительных разделов, подлежащих разработке; заключение по работе).</i></p>	<ul style="list-style-type: none"> <li>– Литературный обзор по теме исследования;</li> <li>– Применение выбранных методов для распознавания ОУМ лазерных пучков;</li> <li>– Анализ полученных результатов, сравнение эффективности рассмотренных методов .</li> </ul>
--	---

<p><b>Перечень графического материала</b>  <i>(с точным указанием обязательных чертежей)</i></p>	<p>– презентация;</p>
--	-----------------------

**Консультанты по разделам выпускной квалификационной работы**  
*(с указанием разделов)*

Раздел	Консультант
Теоретическая часть; Практическая часть	Дудоров В.В.
Финансовый менеджмент, ресурсоэффективность и ресурсосбережение	Рыжакина Т.Г.
Социальная ответственность	Федорчук Ю.М.
Иностранный язык	Панамарёва А.Н.
<b>Названия разделов, которые должны быть написаны на русском и иностранном языках:</b>	
Введение	
Обзор литературы	
Теоретическая часть	

<b>Дата выдачи задания на выполнение выпускной квалификационной работы по линейному графику</b>	01.02.2022
---	------------

**Задание выдал руководитель:**

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор ОИТ ИШИТР ТПУ	Гергет О.М.	Д.Т.Н.		

**Задание принял к исполнению студент:**

Группа	ФИО	Подпись	Дата
ОВМ02	Богач Егор Андреевич		

**ЗАДАНИЕ ДЛЯ РАЗДЕЛА  
«ФИНАНСОВЫЙ МЕНЕДЖМЕНТ, РЕСУРСОЭФФЕКТИВНОСТЬ И  
РЕСУРСОСБЕРЕЖЕНИЕ»**

Студенту:

<b>Группа</b>	<b>ФИО</b>
0BM02	Богач Егор Андреевич

<b>Школа</b>	<b>ИЯТШ</b>	<b>Отделение</b>	<b>ОЭФ</b>
<b>Уровень образования</b>	Магистратура	<b>Направление/специальность</b>	Прикладная математика и информатика

**Исходные данные к разделу «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение»:**

Применения нейронных сетей для распознавания распределений интенсивности лазерных пучков, обладающих различными значениями орбитального углового момента и распространяющихся в турбулентной атмосфере

Работа с научной литературой, представленной в российских и иностранных научных публикациях, аналитических материалах

**Перечень вопросов, подлежащих исследованию, проектированию и разработке:**

1. <i>Оценка коммерческого потенциала, перспективности и альтернатив разработки проекта с позиции ресурсоэффективности и ресурсосбережения</i>	<i>Проведение предпроектного анализа. Определение целевого рынка и проведение его сегментирования. Выполнение SWOT-анализа проекта</i>
2. <i>Планирование и формирование бюджета разработки</i>	<i>Определение целей и ожиданий, требований проекта. Определение бюджета научного исследования</i>
3. <i>Определение ресурсной, финансовой, экономической эффективности разработки</i>	<i>Проведение оценки экономической эффективности, ресурсоэффективности и сравнительной эффективности различных вариантов исполнения</i>

**Перечень графического материала (с точным указанием обязательных чертежей):**

1. *Оценка конкурентоспособности технических решений*
2. *Матрица SWOT*
3. *График проведения и бюджет проекта*
4. *Оценка ресурсной, финансовой и экономической эффективности разработки*

<b>Дата выдачи задания для раздела по линейному графику</b>	01.03.2022
---	------------

**Задание выдал консультант:**

<b>Должность</b>	<b>ФИО</b>	<b>Ученая степень, звание</b>	<b>Подпись</b>	<b>Дата</b>
Доцент	Рыжакина Татьяна Гавриловна	Кандидат экономических наук		01.03.2022

**Задание принял к исполнению студент:**

<b>Группа</b>	<b>ФИО</b>	<b>Подпись</b>	<b>Дата</b>
0BM02	Богач Е.А.		01.03.2022

## «СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ»

Студенту:

<b>Группа</b>	<b>ФИО</b>
ОВМ02	Богач Егор Андреевич

<b>ШКОЛА</b>	<b>ИЯТШ</b>	<b>Отделение школы (НОЦ)</b>	<b>ОЭФ</b>
Уровень образования	Магистр	Направление/специальность	Прикладная математика и информатика

**Тема дипломной работы: «Применения нейронных сетей для распознавания распределений интенсивности лазерных пучков, обладающих различными значениями орбитального углового момента и распространяющихся в турбулентной атмосфере»**

<b>Исходные данные к разделу «Социальная ответственность»:</b>	
1. Характеристика объекта исследования (вещество, материал, прибор, алгоритм, методика, рабочая зона) и области его применения	Применения нейронных сетей для распознавания
Перечень вопросов, подлежащих исследованию, проектированию и разработке:	
<b>1. Производственная безопасность</b> 1.1. Анализ выявленных вредных факторов – Природа воздействия – Действие на организм человека – Нормы воздействия и нормативные документы (для вредных факторов) – СИЗ коллективные и индивидуальные 1.2. Анализ выявленных опасных факторов : – Электробезопасность – Пожаробезопасности	Вредные факторы: – Недостаточная освещенность; – Нарушения микроклимата, допустимые параметры; – Шум, ПДУ, СКЗ, СИЗ; – Повышенный уровень электромагнитного излучения, ПДУ, СКЗ, СИЗ; Опасные факторы: – Электроопасность; класс электроопасности помещения, безопасные номиналы I, U, СКЗ, СИЗ; Проведен расчет освещения рабочего места; представлен рисунок размещения светильников на потолке; – Пожароопасность, категория пожароопасности помещения, марки огнетушителей, их назначение и ограничение применения; Приведена схема эвакуации.
<b>2. Экологическая безопасность:</b> – Решения по обеспечению экологической безопасности	Наличие промышленных отходов: бумага-черновики, вторцвет- и чермет, пластмасса, оргтехника и способы их утилизации;
<b>3. Безопасность в чрезвычайных ситуациях:</b> – разработка превентивных мер по предупреждению ЧС; – разработка действий в результате возникшей ЧС и мер по ликвидации её последствий.	Рассмотрены 2 ситуации ЧС: 1) природная – сильные морозы зимой, (аварии на электро-, тепло-коммуникациях, водоканале, транспорте); 2) техногенная – несанкционированное проникновение посторонних на рабочее место (возможны проявления вандализма, диверсии, промышленного шпионажа), представлены мероприятия по обеспечению устойчивой работы производства в том и другом случае.
<b>4. Перечень нормативно-технической документации.</b>	– ГОСТы, СанПиНы, СНиПы

<b>Дата выдачи задания для раздела по линейному графику</b>	13.05.2022 г.
---	---------------

Задание выдал консультант:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор ТПУ	Федорчук Юрий Митрофанович	д.т.н.		13.05.2022 г.

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
ОВМ02	Богач Е.А.		13.05.2022 г.

Министерство науки и высшего образования Российской Федерации  
 федеральное государственное автономное  
 образовательное учреждение высшего образования  
 «Национальный исследовательский Томский политехнический университет» (ТПУ)

Школа Инженерная школа ядерных технологий  
 Направление подготовки 01.04.02 Прикладная математика и информатика  
 Уровень образования магистратура  
 Отделение школы (НОЦ) Отделение экспериментальной физики  
 Период выполнения весенний семестр 2021/2022 учебного года

Форма представления работы:

Магистерская диссертация

**КАЛЕНДАРНЫЙ РЕЙТИНГ-ПЛАН  
выполнения выпускной квалификационной работы**

Срок сдачи студентом выполненной работы:	01.06.2022
--	------------

Дата контроля	Название раздела (модуля) / вид работы (исследования)	Максимальный балл раздела (модуля)
01.02.2022	Выдача задания	
14.02.2022	Планирование	
21.02.2022	Обсуждение структуры работы	
24.02.2022	Сбор данных и освоение теоретических материалов	
14.03.2022	Обучение нейронных сетей	
25.04.2022	Анализ и оценка полученных результатов	
11.05.2022	Тестирование нейронных сетей, сравнение с другими методами	
30.05.2022	Написание пояснительной записки ВКР	
01.06.2022	Сдача работы	

**СОСТАВИЛ:**

**Руководитель ВКР**

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор ОИТ ИШИТР ТПУ	Гергет О.М.	Д.Т.Н.		

**СОГЛАСОВАНО:**

**Руководитель ООП**

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОЯТЦ ИЯТШ	Семенов М.Е.	к.ф.-м.н.		

## Реферат

Выпускная квалификационная работа содержит 136 страниц, 41 рисунок, 32 таблицы, 87 формул, 52 источника и 3 приложения.

Ключевые слова: орбитальный угловой момент, распознавание, нейронные сети, сверточные нейронные сети, остаточные нейронные сети.

Объектом исследования является: распознавание ОУМ лазерных пучков при их распространении в турбулентной атмосфере по изображениям, формирующимся в плоскости регистрации пространственного распределения интенсивности лазерного излучения.

Цель работы – исследование эффективности применения нейронных сетей для распознавания распределений интенсивности лазерных пучков, обладающих различными значениями ОУМ и распространяющихся в турбулентной атмосфере.

В процессе исследования для распознавания ОУМ применены сверточные и остаточные нейронные сети, метод корреляции изображений и XGBoost с использованием HOG.

В результате исследования проведен анализ эффективности рассмотренных методов для распознавания ОУМ. Для анализа использованы изображения, полученные при численном моделировании двух модификаций схемы формирования лазерных пучков, синтезированных массивом волоконных лазеров. Для такой схемы формирования пучков, обладающих ОУМ, такое исследование проведено впервые.

Область применения: оптика.

Полученные в работе результаты показывают, что нейронные сети позволяют эффективно распознавать ОУМ лазерных пучков, распространяющихся при сильной турбулентности атмосферы.

## Обозначения и сокращения

ОУМ – орбитальный угловой момент;

Лазерный пучок – оптическое излучение, распространяющееся по направлению от лазера, называемой центром лазерного пучка;

Субпучок – лазерный пучок, распространяющийся от одного из лазеров из массива лазеров в схеме формирования пучков, обладающих ОУМ;

Фазовый модулятор – специальное устройство, позволяющее управлять фазами световых пучков;

ПЗС-матрица – устройство, в котором применяется технология управляемого переноса заряда и которое используется для регистрации светового излучения;

Структурная характеристика флуктуаций показателя преломления ( $C_n^2$ ) – параметр, характеризующий силу турбулентности.

ПЭВМ – персональная электронно-вычислительная машина;

SWOT – Strengths (сильные стороны), Weaknesses (слабые стороны), Opportunities (возможности) и Threats (угрозы);

ЧС – чрезвычайная ситуация.

## Оглавление

Введение.....	13
Обзор литературы.....	16
1. Теоретическая часть .....	18
1.1. Описание численного эксперимента .....	18
1.2. Нейронные сети, обучение нейронных сетей .....	22
1.3. Сверточные нейронные сети, классификации изображений .....	26
1.4. Методы выделения признаков из изображений .....	29
1.5. Метод градиентного бустинга деревьев XGBoost.....	30
1.6. Метрики эффективности.....	32
2. Практическая часть.....	35
2.1. Применение сверточных нейронных сетей.....	36
2.2. Применение остаточных нейронных сетей.....	43
2.3. Применение альтернативных методов .....	50
2.4. Сравнение эффективности рассмотренных методов .....	58
3. Финансовый менеджмент, ресурсоэффективность и ресурсосбережение ...	60
3.1. Предпроектный анализ.....	61
3.1.1. Потенциальные потребители результатов исследования.....	61
3.1.2. Анализ конкурентных технических решений .....	62
3.1.3. SWOT-анализ .....	64
3.1.4. Оценка готовности проекта к коммерциализации .....	68
3.1.5. Методы коммерциализации результатов научно-технического исследования.....	69
3.2. Инициация проекта.....	70
3.2.1. Цели и результат проекта .....	70
3.2.2. Организационная структура проекта.....	72
3.2.3. Ограничения и допущения проекта.....	72
3.3. Планирование управления научно-техническим проектом .....	73
3.3.1. План проекта .....	73

3.4. Бюджет научно-технического исследования .....	75
3.4.1. Материальные затраты.....	75
3.4.2. Специальное оборудование .....	75
3.4.3. Основная и дополнительная заработная плата.....	76
3.4.4. Отчисления во внебюджетные фонды .....	78
3.4.5. Накладные расходы.....	79
3.4.6. Формирование бюджета научно-исследовательского проекта .....	80
3.5. Определение ресурсной (ресурсосберегающей), финансовой, бюджетной, социальной и экономической эффективности .....	81
3.5.1. Оценка абсолютной эффективности проекта .....	81
3.5.2. Оценка сравнительной эффективности исследования .....	86
3.6. Выводы по разделу .....	89
4. Социальная ответственность .....	91
4.1. Производственная безопасность .....	91
4.1.1. Отклонение показателей микроклимата в помещении.....	91
4.1.2. Превышение уровней шума.....	93
4.1.3. Повышенный уровень электромагнитных излучений .....	94
4.1.4. Поражение электрическим током .....	96
4.1.5. Пожарная опасность .....	102
4.2. Экологическая безопасность .....	104
4.3. Безопасность в чрезвычайных ситуациях .....	105
4.4. Перечень научно-технической документации.....	107
Заключение .....	109
Список публикаций студента.....	110
Список использованной литературы.....	111
Приложение А .....	117
Приложение Б.....	134
Приложение В.....	136

## Введение

Перспективой ближайших лет является создание квантовых компьютеров, представляющих серьезную угрозу для современных криптографических алгоритмов шифрования информации. Для квантовых компьютеров уже разработаны алгоритмы, позволяющие взломать современные асимметричные криптографические схемы, безопасность которых основана на сложности вычислений [1]. Возникает проблема обеспечения защищенной передачи информации в условиях работы квантовых компьютеров.

Для решения этой проблемы могут быть использованы системы передачи информации, использующие физические явления. Исследования в данной области проводятся, например, в Институте оптики атмосферы им. В.Е. Зуева СО РАН (ИОА СО РАН). В работе [2] предложен метод формирования криптографического ключа на основе флуктуаций электромагнитного излучения, вызванных случайными процессами в атмосфере. Системы связи по лазерному лучу рассматриваются в качестве решения задачи беспроводной защищенной связи.

Системы передачи, основанные на кодировании информации в значениях орбитального углового момента (ОУМ) лазерных пучков, исследуются и быстро развиваются [3, 4]. В работе [5], выполненной в ИОА СО РАН, используется метод формирования световых пучков лазерных пучков массивом волоконных лазерных излучателей. Сформированные таким методом пучки могут быть использованы для передачи информации посредством значений ОУМ. Описанный метод формирования обладающих ОУМ пучков рассматривается в настоящей работе.

ОУМ у лазерного пучка приводит к формированию определенных форм распределения интенсивности в плоскости регистрации излучения. Наличие нулевого ОУМ характеризуется выделяющимся максимумом интенсивности в регистрируемом распределении, а наличие ненулевого ОУМ характеризуется распределением интенсивности, имеющим форму кольца.

Фазовые искажения, возникающие при распространении лазерных пучков в турбулентной атмосфере, приводят к изменениям в регистрируемых распределениях интенсивности, полученные изображения распределений теряют информацию о значении ОУМ у пучков.

Разрушения форм распределений интенсивности приводят к возникновению задачи верного распознавания ОУМ при наличии турбулентных искажений. В настоящее время актуальным направлением является решение задачи распознавания значения ОУМ по распределениям интенсивности, полученным в результате распространения пучков в турбулентной атмосфере с использованием нейронных сетей.

Целью данной работы является исследование эффективности применения нейронных сетей для распознавания распределений интенсивности лазерных пучков, обладающих различными значениями ОУМ и распространяющихся в турбулентной атмосфере.

В настоящей работе рассматриваются пучки, формирующиеся массивом лазерных излучателей, что является отличительной особенностью настоящей работы в сравнении с существующими работами по использованию нейронных сетей для распознавания значений ОУМ у лазерных пучков.

Объектом исследования настоящей работы является распознавание ОУМ лазерных пучков при их распространении в турбулентной атмосфере по изображениям, формирующимся в плоскости регистрации пространственного распределения интенсивности лазерного излучения.

Предмет исследования настоящей работы – эффективность применения нейронных сетей для распознавания изображений, полученных при регистрации пространственных распределений интенсивности при распространении в турбулентной атмосфере вихревых лазерных пучков, обладающих ОУМ.

Практическая значимость результатов настоящей работы заключается в применении обученных нейронных сетей в системе защищенной передачи информации посредством распространения в атмосфере пучков, формирующихся массивом волоконных излучателей и обладающих ОУМ.

Применение обученных нейронных сетей, предложенных в работе позволит производить прием переданной информации в условиях турбулентной атмосферы. Верное распознавание ОУМ у пучков может быть реализовано с использованием дополнительных оптических средств, требующих больших затрат и точной настройки [6], предложенный метод с применением нейронной сети значительно проще и дешевле в реализации.

## Обзор литературы

В настоящее время ведутся работы над решением проблемы организации защищенной линии связи в условиях работы квантовых компьютеров [3]. Существует несколько направлений, в которых проводятся исследования по данной проблеме. Одним из направлений является повышение устойчивости классических криптографических алгоритмов к вычислительным возможностям квантовых компьютеров [7]. Другое направление исследует возможности использования физических явлений для организации безопасной связи. В этом направлении широкое развитие получили исследования, направленные на использование свойств света для обмена информацией по незащищенным каналам посредством распространения вихревых пучков, обладающих ОУМ [8]. В таких пучках информация кодируется в пространственном распределении фазы излучения, в результате чего на приемнике излучения формируются определенные формы пространственного распределения интенсивности для каждого значения ОУМ. Световые пучки, обладающие ОУМ, имеют спиралевидный волновой фронт с азимутальной фазой, лежащей в диапазоне от 0 до  $2\pi l$ , где  $l$  – топологический заряд. Существуют различные методы формирования пучков обладающих ОУМ.

В [9] представлен успешный эксперимент по проведению передачи и приема информации, закодированной в ОУМ лазерного пучка, распространявшегося в атмосфере над городом Вена. Излучение от лазера с длиной волны 532 нм модулировалось пространственным модулятором света для придания ОУМ световым пучкам. В работе показана возможность извлечения информации из ОУМ лазерных пучков, распространяющихся на расстояние 3000 м при сильной турбулентности атмосферы. Исследователям удалось передать и принять цифровые изображения с относительно небольшой величиной ошибочно расшифрованных пикселей.

В работе [5] приведен метод формирования массивом волоконных лазеров пучков, обладающих ОУМ. Численное моделирование подтверждено

экспериментально. Сформированные таким методом пучки также могут использоваться для передачи информации через атмосферу.

Атмосферная турбулентность вносит искажения в фазовые распределения, формирующие ОУМ. Эти искажения проявляются в разрушении форм распределений интенсивности, несущих информацию о значении ОУМ. В настоящее время активно проводятся исследования, направленные на компенсацию влияния турбулентных искажений. Для решения этой задачи наиболее часто применяются нейронные сети.

В работе [10] предложен метод компенсации турбулентных фазовых искажений, в котором сверточные нейронные сети используются для воссоздания фазовых экранов, которые привели к разрушениям форм распределения. Воссозданные сверточными нейронными сетями фазовые экраны затем могут быть использованы для восстановления распределений интенсивности.

В [11] для решения задачи распознавания ОУМ из передаваемых пучков сначала используется дифракционная решетка для извлечения специального набора признаков, которые затем подаются на вход нейронной сети прямого распространения. В работах [12–15] представлено использование сверточных нейронных сетей для распознавания ОУМ.

В уже упомянутых работах по решению задачи распознавания ОУМ лазерных пучков рассматривается схема формирования пучков, использующая только один лазерный излучатель. Особенностью настоящей работы является рассмотрение схемы, использующей массив волоконных излучателей для формирования пучков, обладающих ОУМ.

На основе проведенного анализа литературы для решения задачи распознавания ОУМ было принято исследовать эффективность применения нейронных сетей.

## 1. Теоретическая часть

### 1.1. Описание численного эксперимента

Формирование изображений, полученных в результате регистрации пространственных распределений интенсивности при распространении лазерных пучков в турбулентной атмосфере, осуществлялось численным моделированием. Для формирования изображений использована модель из работы [5], в которую был добавлен учет фазовых искажений, внесенных турбулентностью атмосферы.

Управление пространственными характеристиками пучков, синтезированных матрицей волоконных излучателей, основано на адаптивном управлении фазами излучения в каналах с целью стабилизации заданных фазовых соотношений между отдельными элементами матрицы (субпучками), что позволяет получить требуемое распределение интенсивности в плоскости цели. Схема эксперимента представлена на рисунке 1.1.1.

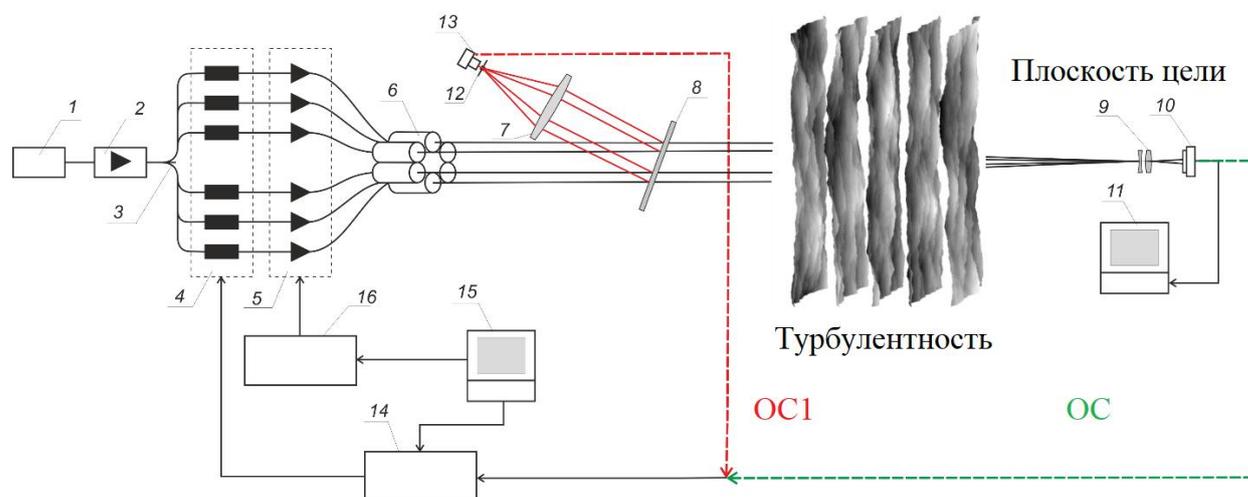


Рисунок 1.1.1 – Схема эксперимента: 1 – узкополосный лазер, 2 – волоконно-оптический усилитель, 3 – волоконный разветвитель 1x8, 4 – фазовые модуляторы, 5 – усилители мощности, 6 – волоконные коллиматоры, 7 – длиннофокусная линза, 8 – светоделительная пластина, 9 – коллиматор, 10 – ПЗС-матрица, 11 – компьютер, 12 – малая диафрагма, 13 – широкополосный фотоприемник, 14 – многоканальный оптимизирующий SPGD-процессор, 15 – управляющий компьютер, 16 – контроллер усилителей мощности

В работе рассмотрены две модификации схемы. В рассматриваемой схеме имеются две плоскости, расположенные в фокусе линзы 7, где формируется синтезированный пучок. В первой модификации схемы плоскость цели располагается в плоскости регистрации ПЗС-матрицы 10, а вторая плоскость расположена в плоскости малой диафрагмы 12 фотоприемника 13, и служит для формирования сигнала обратной связи по внутреннему контуру, необходимого для синхронизации фаз. Предложенная адаптивная схема позволяет компенсировать сдвиги фаз, вызванные шумами оптической системы, управлять результирующим распределением интенсивности в плоскости цели, однако, не позволяет компенсировать турбулентные искажения фазового фронта.

Во второй модификации схемы сигнал обратной связи регистрируется непосредственно в плоскости цели. В качестве источника сигнала обратной связи выступает центральный пиксель ПЗС-матрицы 10. Данная схема позволяет компенсировать фазовые искажения, вносимые как атмосферой, так и оптической системой.

При отсутствии турбулентности в плоскости мишени формируются распределения интенсивности, представленные на рисунке 1.1.2

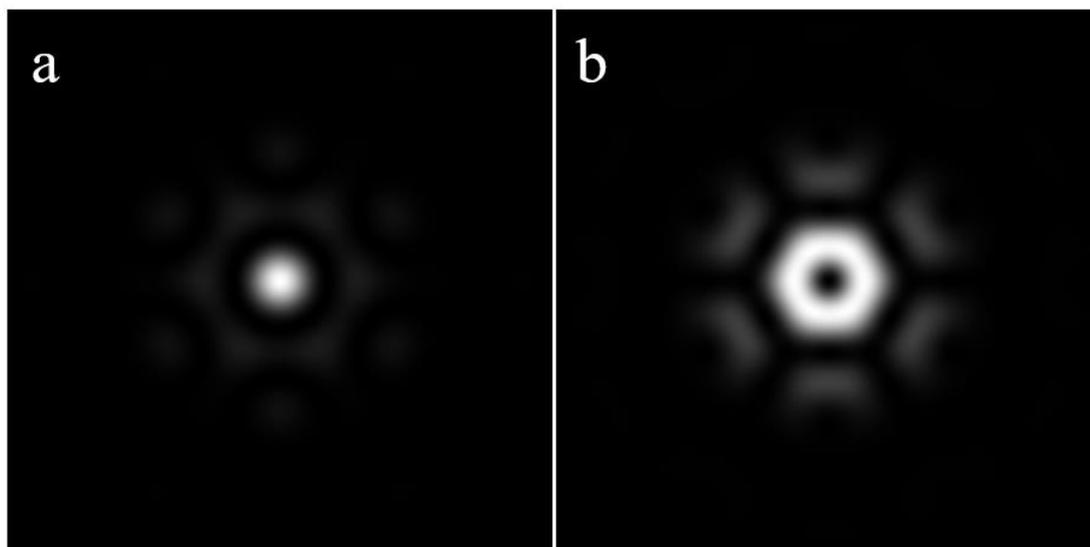


Рисунок 1.1.2 – Результаты моделирования в отсутствии турбулентности:

а) при значении ОУМ = 0, б) при значении ОУМ = 1.

Полученное пространственное распределение интенсивностей несет информацию о значении ОУМ.

Для описания распространения лазерного излучения в регулярных и случайно неоднородных средах при численном моделировании использовалось параболическое уравнение для скалярного поля  $E$  [16]. Решение этого уравнения в численной схеме производилось с применением метода фазовых экранов [16,17]. Для моделирования флуктуаций показателя преломления использовался спектр Эндрюса [18,19]. Для синхронизации фаз в обеих модификациях схемы использовался алгоритм стохастического параллельного градиентного спуска (SPGD) [21].

Для характеристики уровня турбулентности в настоящей работе используется такой параметр, как структурная характеристика показателя преломления  $C_n^2$  [20]. В зависимости от значения  $C_n^2$  условно разделяют три диапазона силы турбулентности [14]:

- слабая турбулентность –  $C_n^2 < 1 \cdot 10^{-15} \text{ м}^{-2/3}$ ;
- слабая турбулентность –  $1 \cdot 10^{-15} < C_n^2 < 1 \cdot 10^{-14} \text{ м}^{-2/3}$ ;
- слабая турбулентность –  $C_n^2 > 1 \cdot 10^{-14} \text{ м}^{-2/3}$ .

В работе использовались изображения распределений интенсивности, смоделированные при распространении пучков на расстояние 1500 м для значений  $C_n^2 \in [1 \cdot 10^{-16}; 5 \cdot 10^{-14}] \text{ м}^{-2/3}$  и для значений ОУМ равных 0 и 1 с использованием модификации схемы с обратной связью по внутреннему контуру. Эти изображения использовались для обучения и оценки эффективности предложенных методов. Для анализа эффективности распознавания предложенных методов на различных дистанциях распространения лазерных пучков использованы изображения распределений, полученные с использованием модификации схемы с обратной связью по внешнему контуру.

Учет турбулентности атмосферы методом фазовых экранов [16] приводит к разрушению пространственных распределений интенсивности, несущих информацию о значении ОУМ. На рисунке 1.1.3 представлены примеры

распределений интенсивности, полученные при различных значениях структурной характеристики показателя преломления.

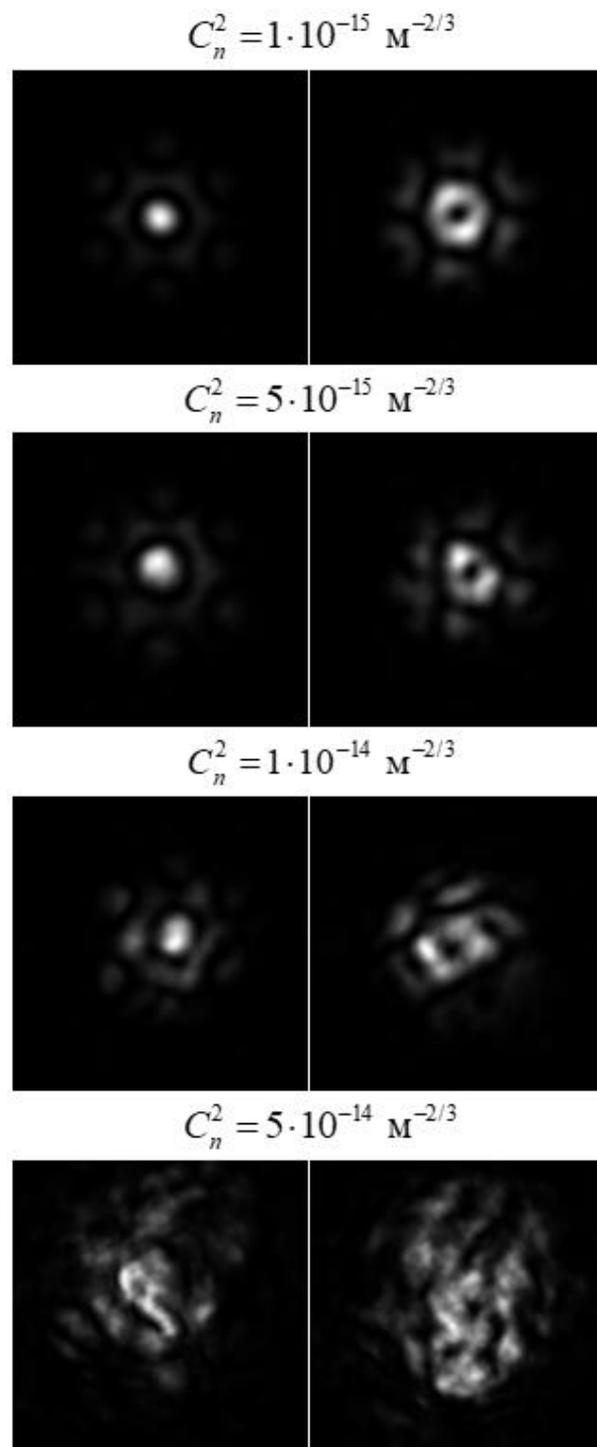


Рисунок 1.1.3 – Распределения интенсивностей для различных значений  $C_n^2$ : слева представлены распределения для ОУМ = 0, справа – для ОУМ = 1

## 1.2. Нейронные сети, обучение нейронных сетей

Идея создания искусственных нейронных сетей основана на устройстве и работе нейронов в человеческом мозге [22]. Первой моделью нейронной сети считается линейный перцептрон Розенблатта, который он описал в 1950-х годах [23]. Перцептрон Розенблатта можно рассматривать как линейную модель классификации [22]. На вход перцептрона подается одномерный массив  $x$ , имеющий длину  $N$ . Входной массив умножается на массив весов  $w$ , а затем результаты умножения суммируются и подаются в качестве аргумента в функцию активации  $f$ . Результат работы модели  $y$  формируется согласно выражению (1.2.1).

Перцептроны являются элементарными единицами, из которых строятся многослойные нейронные сети. Каждый слой такой нейронной сети состоит (обычно) из нескольких нейронов.

На рисунке 1.2.1 изображена схема организации нейронной сети прямого распространения. Для сетей прямого распространения используются 3 типа слоев: входные слои, скрытые слои и выходные слои. В качестве входных данных в таких сетях используются только одномерные массивы.

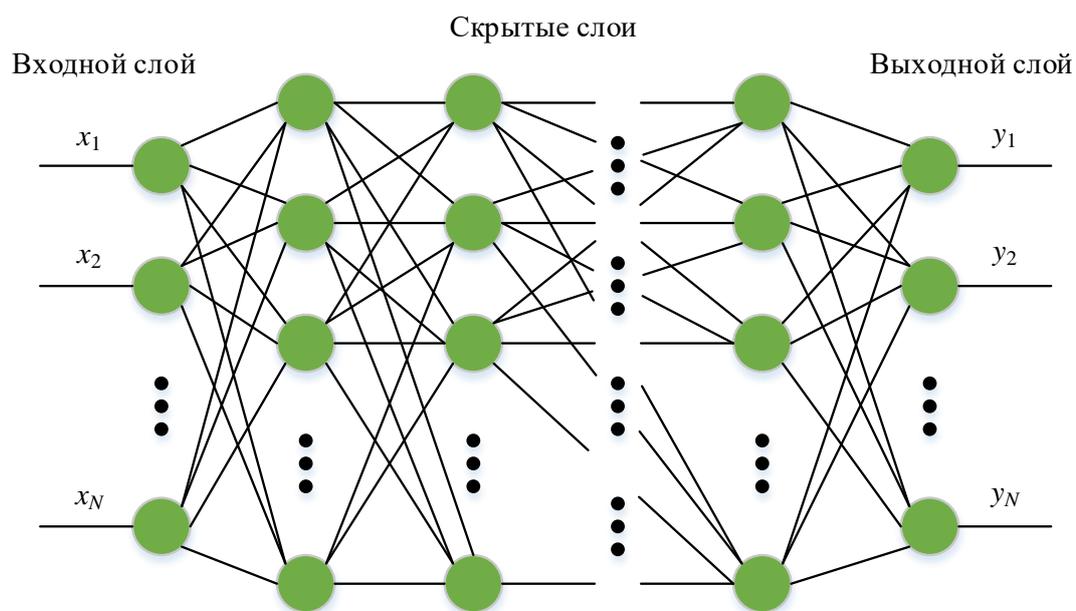


Рисунок 1.2.1 – Схема организации нейронной сети прямого распространения

На входной слой поступают исходные данные. Количество нейронов во входном слое соответствует размеру входного массива данных. На вход каждого нейрона входного слоя подается одно значение входного массива. Выходное значение каждого нейрона входного слоя связано со всеми нейронами скрытого слоя, идущего за входным слоем, с помощью весовых коэффициентов  $w$ .

Скрытых слоев в нейронной сети прямого распространения может быть несколько. Количество нейронов в этих слоях, как и количество слоев, определяется при создании нейронной сети и ограничивается вычислительными возможностями. На вход каждого нейрона скрытого слоя подаются все выходные значения нейронов из предыдущего слоя. Все выходные значения нейронов скрытого слоя подаются на вход каждого нейрона следующего слоя. То есть каждый нейрон скрытого слоя связан на входе со всеми нейронами предыдущего слоя, а на выходе – со всеми нейронами следующего слоя. Связь нейронов осуществляется также посредством весовых коэффициентов  $w$ . Входные весовые коэффициенты скрытого слоя являются выходными для предыдущего слоя, а выходные коэффициенты скрытого слоя являются входными для следующего слоя [22].

Выходной слой формирует «решение» нейронной сети, основанное на входных данных. Количество нейронов в этом слое зависит от решаемой задачи: в задаче регрессии в выходном слое используется только 1 нейрон, а в задаче классификации количество нейронов соответствует количеству определяемых классов. Все нейроны выходного слоя связаны с каждым нейроном предыдущего слоя также через весовые коэффициенты  $w$ . При решении задачи классификации в выходном слое может применяться softmax функция, позволяющая получить в качестве выходных такие значения, которые могут интерпретироваться в качестве вероятности принадлежности примера к какому-то из классов [22].

Каждый  $j$ -ый нейрон любого слоя (кроме входного) нейронной сети прямого распространения связан с нейронами предыдущего слоя согласно выражению (1.2.1):

$$y_j = f\left(\sum_{i=0}^N w_{ji}x_i\right), \quad (1.2.1)$$

где  $y_j$  – выход  $j$ -го нейрона рассматриваемого слоя;

$f$  – функция активации  $j$ -го нейрона рассматриваемого слоя;

$w_{ji}$  – весовой коэффициент связи  $j$ -го нейрона рассматриваемого слоя с  $i$ -ым нейроном предыдущего слоя;

$x_i$  – выход  $i$ -го нейрона предыдущего слоя.

$N$  – количество нейронов в предыдущем слое.

В глубоком обучении с учителем существуют понятия прямого и обратного распространения [22]. При прямом распространении размеченные данные подаются на вход нейронной сети и проходят через все слои, формируются значения на выходном слое. Далее выходные значения, полученные после прямого распространения, сравниваются с реальным значением предсказываемой функции в задаче регрессии или с реальной меткой класса в задаче классификации. В результате сравнения вычисляется значение функции потерь (ошибка работы нейронной сети), обозначаемая как  $L$ . Это значение затем распространяется в обратном направлении, обновляя весовые коэффициенты  $w$  и обучая нейронную сеть. В качестве функции ошибки используются, например, среднее квадратичное отклонение или перекрестная энтропия. Весовые коэффициенты обновляются таким образом, чтобы минимизировать ошибку на каждом шаге обучения, то есть решается задача оптимизации. Для решения задачи оптимизации (минимизации функции потерь) был придуман ряд алгоритмов: градиентный спуск, adagrad, adam, adamax [22].

На шаге  $t$  оптимизации значения весовых коэффициентов  $j$ -го нейрона в слое  $l$  обновляются согласно выражению (1.2.2).

$$w_t^{l,j} = w_{t-1}^{l,j} + \Delta w_t^{l,j}, \quad (1.2.2)$$

где  $w_t^{l,j}$  – вектор весовых значений  $j$ -го нейрона в слое  $l$  на шаге  $t$ ;

$w_{t-1}^{l,j}$  – вектор весовых значений  $j$ -го нейрона в слое  $l$  на шаге  $t - 1$ ;

$\Delta w_t^{l,j}$  – вектор обновлений весов  $j$ -го нейрона в слое  $l$  на шаге  $t$ .

Вектор обновления весов при использовании классического градиентного спуска определяется согласно выражению (1.2.3):

$$\Delta w_t^{l,j} = -\eta \nabla L(w_t^{l,j}), \quad (1.2.3)$$

где  $\eta$  – параметр, называемый скоростью обучения;

$\nabla L(w)$  – градиент функции ошибки по весовым коэффициентам  $w$ .

Расчет градиентов в нейронных сетях осуществляется по цепному правилу. Градиент по весовым коэффициентам рассчитывается согласно выражению (1.2.4):

$$\frac{\partial L}{\partial w_j^l} = \sum_i \frac{\partial L}{\partial y_i^{l+1}} \frac{\partial y_i^{l+1}}{\partial f_i^{l+1}} \frac{\partial f_i^{l+1}}{\partial w_{ji}^{l+1}} x_i^{l+1}, \quad (1.2.4)$$

Распространения ошибки на предыдущий слой осуществляется согласно выражению (1.2.5):

$$\frac{\partial L}{\partial x_j^l} = \sum_i \frac{\partial L}{\partial y_i^{l+1}} \frac{\partial y_i^{l+1}}{\partial f_i^{l+1}} \frac{\partial f_i^{l+1}}{\partial x_i^{l+1}} w_{ji}^{l+1}, \quad (1.2.5)$$

### 1.3. Сверточные нейронные сети, классификации изображений

Нейронные сети прямого распространения работают только с одномерными массивами данных, что не подходит для построения моделей классификации изображений, в которых важную роль играет не только интенсивность пикселей, но и их взаимное расположение в пространстве. Сверточные сети позволили учитывать пространственное положение пикселей в изображениях при построении моделей, а сейчас они показывают высокую точность в соревнованиях по распознаванию изображений ImageNet [24]. В сверточных нейронных сетях используются специальные операции для выявления признаков из пространственного и цветового распределения.

Операция свертки, в честь которых сверточные нейронные сети получили свое название, описывается выражением (1.3.1):

$$y_{i,j}^l = \sum_{a,b=-d}^d w_{a,b} x_{i+a,j+a}^l, \quad (1.3.1)$$

где  $y_{i,j}^l$  – результат операции свертки;

$i, j$  – координаты пикселя в изображении;

$w_{a,b}$  – весовые коэффициенты фильтра, который имеет размер  $2d + 1 \times 2d + 1$ ;

$a, b$  – координаты элемента в фильтре;

$x_{i+a,j+a}^l$  – выход предыдущего слоя.

В операции свертки с фильтром, имеющим размер  $2d + 1 \times 2d + 1$ , для обхода всего изображения используется только  $(2d + 1)^2$  весов. При этом выходом свертки является массив с размером  $M \times N$  или  $M - d + 1 \times N - d + 1$ , в зависимости от способа обработки краевых пикселей изображения [22]. В каждом сверточном слое обычно используется несколько фильтров для операции свертки.

Кроме учета пространственного распределения пикселей, свертка дает еще одно преимущество в сравнении с сетями прямого распространения:

операция свертки позволяет получить большое количество признаков, используя небольшое количество весовых коэффициентов. К примеру, при использовании фильтра размером  $3 \times 3$  к одноканальному изображению размером  $28 \times 28$  с учетом того, что в изображение размером  $28 \times 28$  фильтр помещается  $26 \times 26$  раз, на выходе свертки получится  $26 \cdot 26 = 676$  признаков и всего 9 обучаемых весов. При этом в сети прямого распространения для получения 676 признаков понадобилось бы  $28 \cdot 28 \cdot 676 = 529984$  весов.

За операцией свертки следует операция активации, которая представляет собой взятие активационной функции от каждого выходного значения свертки. Описание активации представлено в выражении (1.3.2).

$$z_{i,j}^l = f(y_{i,j}^l), \quad (1.3.2)$$

где  $f$  – функция активации;

$z_{i,j}^l$  – результат активации.

После активации может использоваться слой подвыборки (субдискретизации) [22]. Слой субдискретизации используется для прореживания матрицы признаков. Обычно он реализуется как взятие максимального или среднего значения по скользящему окну. В выражении (1.3.3) представлено определение субдискретизации с окном размера  $2d + 1 \times 2d + 1$ .

$$x_{i,j}^{l+1} = \max_{-d \leq a \leq d, -d \leq b \leq d} z_{i+a, j+b}^l, \quad (1.3.3)$$

где  $x_{i,j}^{l+1}$  – выходное значение субдискретизации.

Комбинации из слоев свертки, активации и субдискретизации могут несколько раз следовать друг за другом. После этих комбинаций обычно идет один или несколько полносвязных слоев [22], после которых идет выходной слой.

На рисунке 1.3.1 представлен пример архитектуры сверточной нейронной сети, предназначенной для классификации изображений.

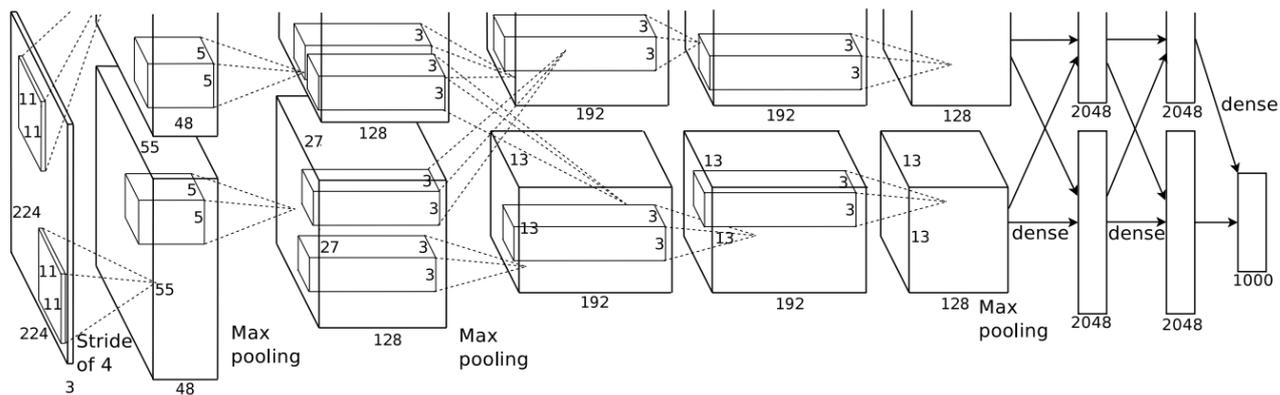


Рисунок 1.3.1 – Пример архитектуры сверточной нейронной сети, предназначенной для классификации изображений [24]

В глубоких нейронных сетях наблюдаются проблемы деградации и затухания градиентов. Представленная в [25] идея остаточного обучения позволяет решить и эти проблемы. На рисунке 1.3.2 представлен блок, использующийся в остаточном обучении.

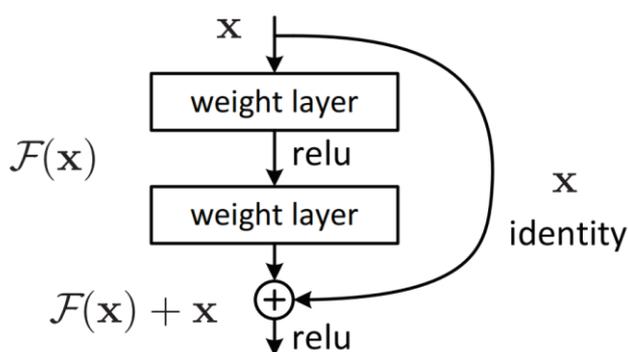


Рисунок 1.3.2 – Остаточный блок

Идея остаточного обучения – перенос информации в обход вычислительных слоев. Математически это представляется в виде суммы выходных массивов текущего вычисляющего слоя и его входного массива или входного массива остаточного блока (выражение 1.2.4).

$$y_k = F(x_k) + x_k, \quad (1.3.4)$$

где  $y_k$  – выход  $k$ -го слоя;

$F(x_k)$  – выход вычислительной части  $k$ -го слоя;

$x_k$  – входной массив  $k$ -го слоя.

#### 1.4. Методы выделения признаков из изображений

Гистограмма ориентированных градиентов (Histogram of oriented gradients – HOG) – метод извлечения признаков из изображения, основанный на расчете амплитуд и направлений градиентов. Результатом применения HOG к изображению является гистограмма амплитуд градиентов по направлениям [26].

Для расчета HOG изображение делится на локальные регионы. В каждой точке локального региона рассчитываются градиенты  $dx$  и  $dy$ . Для расчета градиентов используется фильтр Собеля [27]. Полученные градиенты затем используются для расчета амплитуд градиентов  $m(x, y)$  и их направлений  $\theta(x, y)$  по формулам:

$$m(x, y) = \sqrt{dx(x, y)^2 + dy(x, y)^2} \quad (1.4.1)$$

и

$$\theta(x, y) = \begin{cases} \arctg\left(\frac{dy(x, y)}{dx(x, y)}\right) - \pi, & \text{если } dx < 0, dy < 0, \\ \arctg\left(\frac{dy(x, y)}{dx(x, y)}\right) + \pi, & \text{если } dx < 0, dy > 0, \\ \arctg\left(\frac{dy(x, y)}{dx(x, y)}\right), & \text{в остальных случаях.} \end{cases} \quad (1.4.2)$$

Каждый локальный регион делится на клетки. В каждой клетке рассчитывается гистограмма суммарных амплитуд для (обычно) 9 направлений. Углы направлений в таком случае представляют угловые промежутки, имеющие ширину  $360^\circ / 9 = 40^\circ$ . Вектор, соответствующей этой гистограмме, представляет извлеченные признаки – HOG.

При разделении исходного изображения на  $R$  локальных регионов, каждый из которых поделен на  $C$  клеток в результате расчета HOG получится вектор длиной  $R \cdot C \cdot 9$ . Этот вектор описывает локальную форму объектов, неся информацию о каждой расчетной клетке.

## 1.5. Метод градиентного бустинга деревьев XGBoost

Бустинг деревьев – это эффективный метод машинного обучения, который в настоящее время получил значительное распространение. XGBoost – масштабируемая комплексная система бустинга деревьев, которая широко используется во многих задачах машинного обучения для получения наилучших результатов.

Для набора данных с  $n$  примерами и  $m$  признаками в ансамбле деревьев используется  $K$  аддитивных функций для предсказания выходного значения [28]:

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) \quad (1.5.1)$$

где  $\hat{y}_i$  – предсказанное моделью значение для  $i$ -го примера;

$x_i$  –  $i$ -ый пример из набора данных.

Для обучения такой модели используется следующая функция потерь

$$L = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k) \quad (1.5.2)$$

где  $l(\hat{y}_i, y_i)$  – дифференцируемая выпуклая функция потерь, измеряющая расстояние между предсказанием  $\hat{y}_i$  и истинным значением  $y_i$ ;

$\Omega(f_k)$  – параметр регуляризации.

Вторая часть в выражении (1.5.2) отвечает за регуляризацию, штрафует модель за ее сложность. Регуляризация помогает сгладить веса при обучении и избежать переобучения модели. Параметр определяется по следующей формуле:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \|\omega\|^2 \quad (1.5.3)$$

где  $\gamma, \lambda$  – коэффициенты регуляризации;

$T$  – количество листьев в дереве;

$\omega$  – вектор весов модели.

В градиентном бустинге модель обучается аддитивно. Пусть  $\hat{y}_i^{(t)}$  предсказание для  $i$ -го примера на  $t$ -ой итерации. Необходимо также добавить  $f_t$ , чтобы оптимизировать следующую функцию потерь [28]:

$$L^{(t)} = l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) \quad (1.5.4)$$

Это означает, что было жадно добавлена  $f_t$  в функцию потерь, что серьезно улучшает модель в сравнении с (1.5.2). Аппроксимация второго порядка позволяет быстро оптимизировать целевую функцию [29]:

$$\tilde{L}^{(t)} = \left[ l(y_i, \hat{y}_i^{(t-1)}) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t) \quad (1.5.5)$$

где  $g_i = \frac{\partial l(y_i, \hat{y}_i^{(t-1)})}{\partial \hat{y}_i^{(t-1)}}$ ;

$$h_i = \frac{\partial^2 l(y_i, \hat{y}_i^{(t-1)})}{(\partial \hat{y}_i^{(t-1)})^2}.$$

Если убрать константы, получится упрощенное выражение целевой функции потерь на шаге  $t$ :

$$\tilde{L}^{(t)} = \left[ g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t) \quad (1.5.6)$$

Пусть  $I_j$  – множество примеров из набора данных, которые после разделения в узле попадают в  $j$ -ый лист. Тогда выражение (1.5.5) с раскрытием  $\Omega(f_t)$  может быть переписано следующим образом:

$$\begin{aligned} \tilde{L}^{(t)} &= \sum_{i=1}^n \left[ g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 = \\ &= \sum_{j=1}^T \left[ \left( \sum_{i \in I_j} g_i \right) \omega_j + \frac{1}{2} \left( \sum_{i \in I_j} h_i + \lambda \right) \omega_j^2 \right] + \gamma T \end{aligned} \quad (1.5.7)$$

Для заданной структуры  $q(x)$  оптимальный вес  $\omega_j^*$  для  $j$ -го листа определяется по формуле:

$$\omega_j^* = -\frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda}, \quad (1.5.8)$$

а соответствующее значение функции потерь рассчитывается по следующей формуле:

$$L^{(t)}(q) = -\frac{1}{2} \sum_{j=1}^T \frac{\left(\sum_{i \in I_j} g_i\right)^2}{\sum_{i \in I_j} h_i + \lambda} + \gamma T, \quad (1.5.9)$$

Обычно невозможно перечислить все возможные структуры дерева  $q$ . Вместо этого используется жадный алгоритм, начинающий с одного листа и итеративно добавляющий ветви в дерево. Пусть  $I_L$  и  $I_R$  – это множества примеров левого и правого узлов после разделения и соответственно  $I = I_L \cup I_R$ . Уменьшение функции потерь после разделения можно получить по формуле:

$$L_{split} = -\frac{1}{2} \left[ \frac{\left(\sum_{i \in I_L} g_i\right)^2}{\sum_{i \in I_L} h_i + \lambda} + \frac{\left(\sum_{i \in I_R} g_i\right)^2}{\sum_{i \in I_R} h_i + \lambda} - \frac{\left(\sum_{i \in I} g_i\right)^2}{\sum_{i \in I} h_i + \lambda} \right] - \gamma T. \quad (1.5.10)$$

Эта формула обычно используется для оценки кандидата для разделения.

## 1.6. Метрики эффективности

Правильность работы модели классификации может быть оценена через подсчет количества верно распознанных примеров класса ( $TP$ ), количества примеров, неверно распознанных принадлежащими к классу ( $FP$ ), количества примеров класса, не распознанных принадлежащими классу ( $FN$ ), количества примеров, верно распознанных не принадлежащими классу ( $TN$ ) [30]. Эти числа формируют таблицу – матрицу неточностей (confusion matrix). Пример такой матрицы для задачи бинарной классификации представлен в таблице 1.

Таблица 1 – Матрица неточностей для задачи бинарной классификации

	определен как positive	определен как negative
positive	TP	FP
negative	FN	TN

Для оценки работы моделей классификации в машинном обучении принято использовать метрики *accuracy*, *precision*, *recall* и *F1-score* [31].

Метрика *accuracy* показывает долю правильно предсказанных классов из количества всех размеченных примеров [31]. Для расчета *accuracy* в задаче бинарной классификации используется формула:

$$accuracy = \frac{TP + TN}{TP + FN + TN + FP}. \quad (1.6.1)$$

В задаче классификации с  $K \geq 3$  классами для нахождения метрики *accuracy* модели для  $i$ -го класса используется формула:

$$accuracy_i = \frac{TP_i + TN_i}{TP_i + FN_i + TN_i + FP_i}, \quad (1.6.2)$$

а для нахождения средней метрики *accuracy* модели для всех классов используется следующая формула:

$$accuracy_M = \frac{\sum_{i=1}^K \frac{TP_i + TN_i}{TP_i + FN_i + TN_i + FP_i}}{K}. \quad (1.6.3)$$

Метрика *precision* показывает долю верно определенных примеров класса среди всех примеров, определенных принадлежащими этому классу [31]. В задаче бинарной классификации *precision* рассчитывается формуле:

$$precision = \frac{TP}{TP + FP}. \quad (1.6.4)$$

В задаче классификации с  $K \geq 3$  классами для нахождения метрики *precision* модели для  $i$ -го класса используется формула:

$$precision_i = \frac{TP_i}{TP_i + FP_i}, \quad (1.6.5)$$

а для нахождения средней метрики *precision* модели для всех классов используется следующая формула:

$$precision_M = \frac{\sum_{i=1}^K \frac{TP_i}{TP_i + FP_i}}{K}. \quad (1.6.6)$$

Метрика *recall* показывает долю верно определенных примеров класса среди всех примеров класса, обработанных моделью [31]. Для расчета *recall* в задаче бинарной классификации используется формула:

$$recall = \frac{TP}{TP + FN}. \quad (1.6.7)$$

В задаче классификации с  $K \geq 3$  классами для нахождения метрики *recall* модели для  $i$ -го класса используется формула:

$$recall_i = \frac{TP_i}{TP_i + FN_i}, \quad (1.6.8)$$

а для нахождения средней метрики *recall* модели для всех классов используется следующая формула:

$$recall_M = \frac{\sum_{i=1}^K \frac{TP_i}{TP_i + FN_i}}{K}. \quad (1.6.9)$$

Метрика *F1-score* используется при сравнении моделей классификации. Эта метрика позволяет свести оценки эффективности модели, полученные с использованием *precision* и *recall*, в одно число. В задаче бинарной классификации для расчета *F1-score* используется формула [32]:

$$F1-score = \frac{2 \cdot precision \cdot recall}{precision + recall}. \quad (1.6.10)$$

В задаче классификации с  $K \geq 3$  классами для нахождения *F1-score* модели для  $i$ -го класса используется формула:

$$F1-score_i = \frac{2 \cdot precision_i \cdot recall_i}{precision_i + recall_i}. \quad (1.6.11)$$

а для нахождения средней метрики *F1-score* модели для всех классов используется следующая формула:

$$F1-score_M = \frac{\sum_i^K \frac{2 \cdot precision_i \cdot recall_i}{precision_i + recall_i}}{K}. \quad (1.6.12)$$

## 2. Практическая часть

В настоящей работе использованы изображения размером  $250 \times 250$  в оттенках серого. Изображения соответствуют распределениям интенсивности, полученным в плоскости регистрации при численном моделировании схемы формирования пучков [5]. Примеры изображений приведены в приложении В.

Модификация схемы [5] с обратной связью по внутреннему контуру использована для численного моделирования изображений для обучающего и валидационного набора изображений. Эти изображения сформированы распространении пучков на дистанцию 1500 м для различных уровней силы турбулентности при  $C_n^2 \in (1 \cdot 10^{-16}; 5 \cdot 10^{-14}) \text{ м}^{-2/3}$ . Такой диапазон силы турбулентности характеризует все природные атмосферные условия.

Модификация схемы [5] с обратной связью по внешнему контуру использована для численного моделирования изображений для набора изображений, необходимых для дополнительной оценки обобщающей способности рассматриваемых методов и исследования влияния дистанции распространения пучков на точность распознавания. Эти изображения сформированы при двух уровнях силы турбулентности при  $C_n^2 = 3 \cdot 10^{-14} \text{ м}^{-2/3}$  и  $C_n^2 = 7.2 \cdot 10^{-15} \text{ м}^{-2/3}$  на различных дистанциях распространения пучков, лежащих в диапазоне  $L \in (1000; 4500) \text{ м}$ .

Обучающий набор изображений сформирован при распространении пучков на дистанцию 1500 метров при уровнях силы турбулентности, лежащих в диапазоне  $C_n^2 \in (1 \cdot 10^{-14}; 5 \cdot 10^{-14}) \text{ м}^{-2/3}$ . Обучающий набор состоял из 20000 изображений по 10000 изображений для ОУМ = 0 и ОУМ = 1. При обучении моделей обучающий набор делился на тренировочный и тестовый наборы: тренировочный набор состоял из 75 % изображений обучающего набора, а тестовый – из 25 % оставшихся изображений.

Валидационный набор изображений содержал 32000 изображений по 16000 изображений для каждого из рассматриваемых значений ОУМ.

## 2.1. Применение сверточных нейронных сетей

Разработанные для решения задачи распознавания архитектуры сверточных нейронных сетей представлена на рисунке 2.1.1.

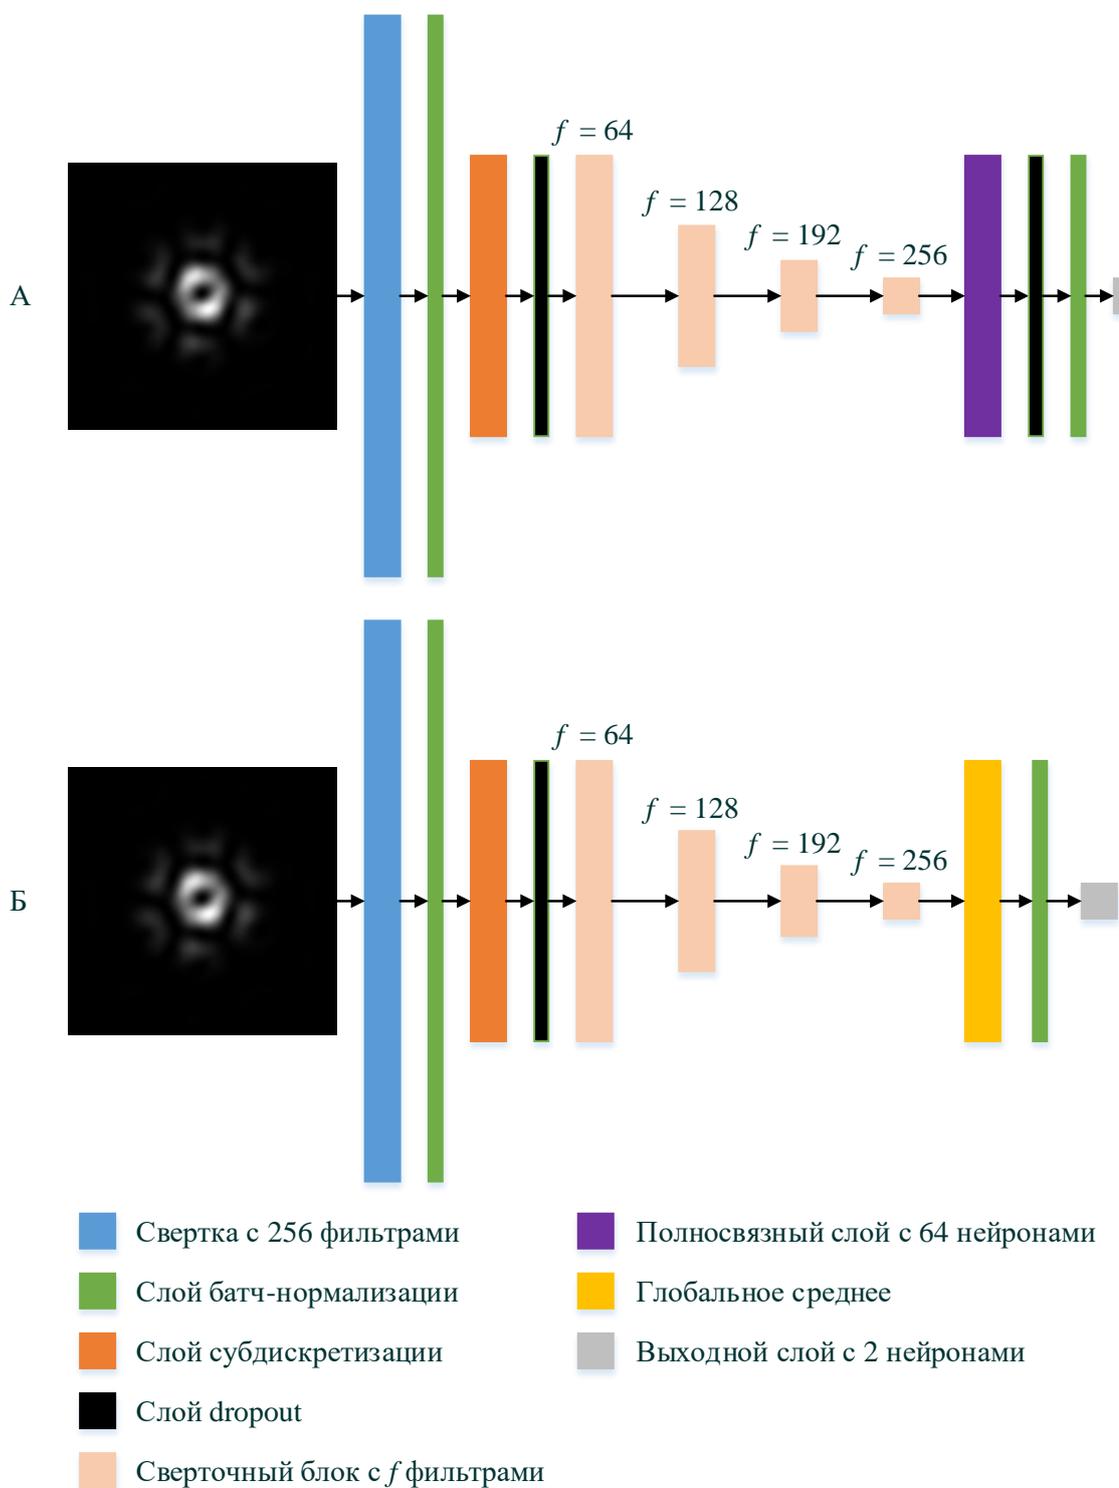


Рисунок 2.1.1 – Архитектуры сверточных нейронных сетей:

А – вариант архитектуры с полносвязным слоем;

Б – вариант архитектуры с взятием глобального среднего

В работе рассмотрены два варианта архитектуры сверточной нейронной сети: с полносвязным слоем перед выходным слоем и со слоем глобального взятия среднего. Структура сверточных блоков, используемых в предложенных архитектурах сверточных нейронных сетей, представлена на рисунке 2.1.2. В сверточных слоях использована функция активации LeakyReLU, а в выходном слое применялась функция softmax [22]. В качестве функции потерь рассчитывалась перекрестная энтропия.

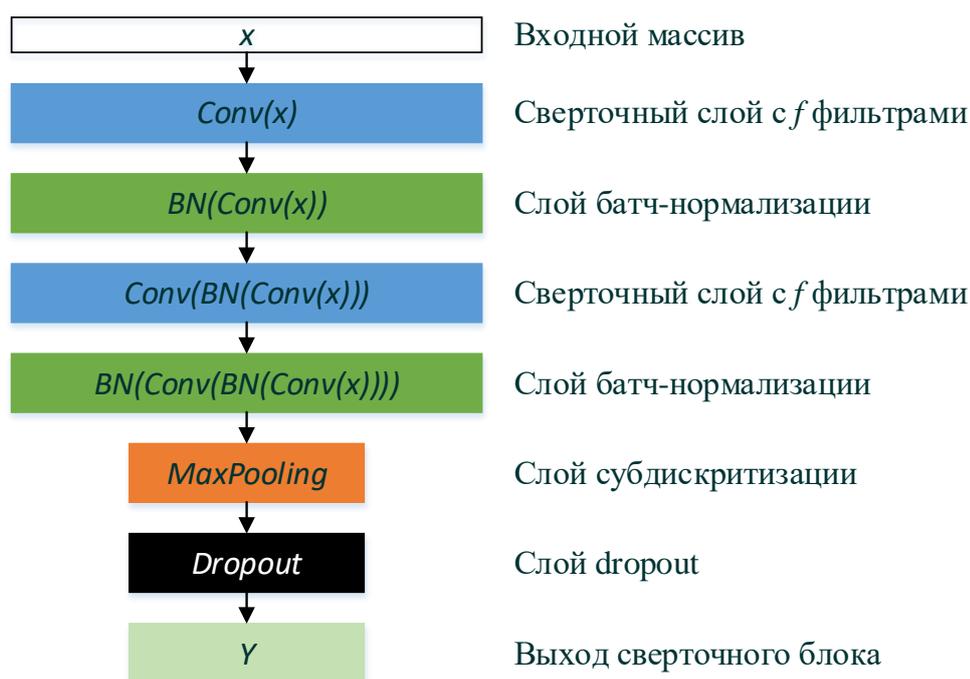


Рисунок 2.1.2 – Структура сверточных блоков

В сверточных нейронных сетях использовалась L2 регуляризация и слои dropout для исключения переобучения. Для ускорения обучения нейронных сетей использовалась нормализация по мини-батчам.

В качестве характеристики качества распознавания, полученного с использованием рассматриваемых методов, применялась точность распознавания [14]. Точность распознавания представляет собой отношение количества верно распознанных изображений ко всему количеству обработанных изображений. Точность распознавания соответствует метрике *accuracy* и рассчитывается по аналогичной формуле.

В качестве порога распознавания по силе турбулентности в настоящей работе было принято такое значение  $C_{nT}^2$ , для которого точность распознавания составляет не менее 95 % на всем промежутке значений  $C_n^2 \in (1 \cdot 10^{-16}; C_{nT}^2) \text{ м}^{-2/3}$ .

Зависимости точности распознавания сверточных нейронных сетей от величины структурной характеристики показателя преломления представлены на рисунках 2.1.3 и 2.1.4.

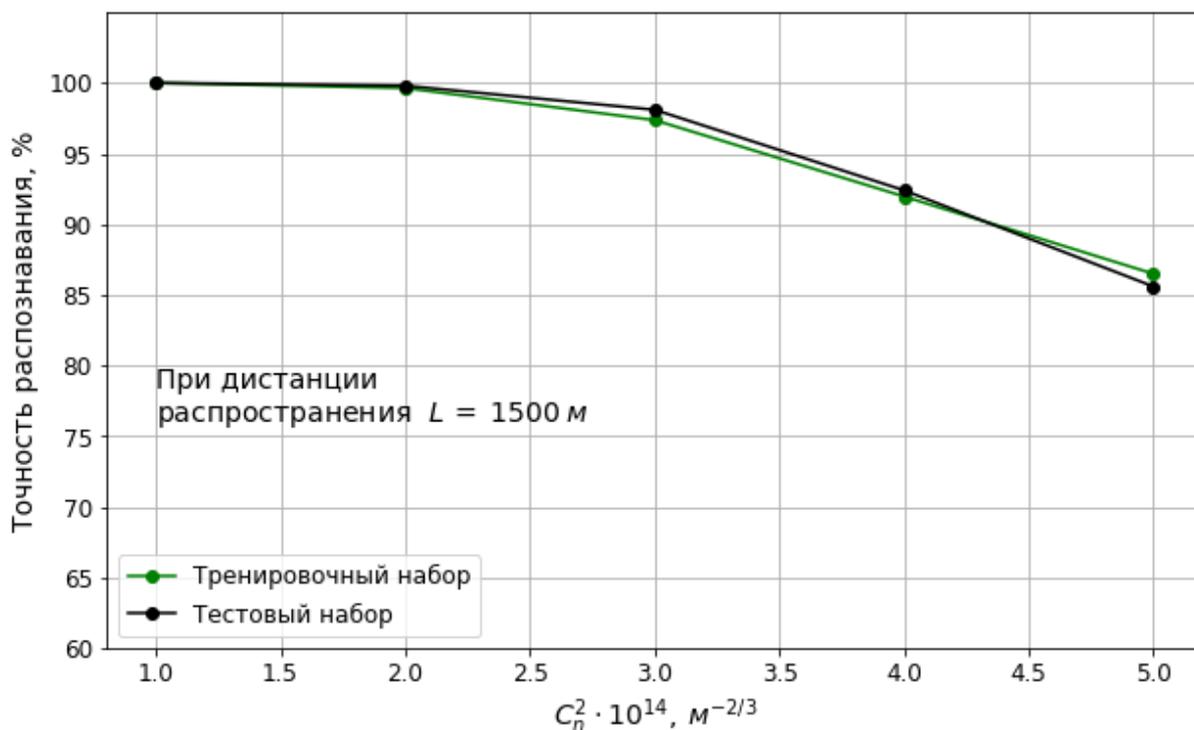


Рисунок 2.1.3 – Зависимость точности распознавания сверточной нейронной сети с полносвязным слоем от  $C_n^2$  для тренировочного и тестового наборов изображений

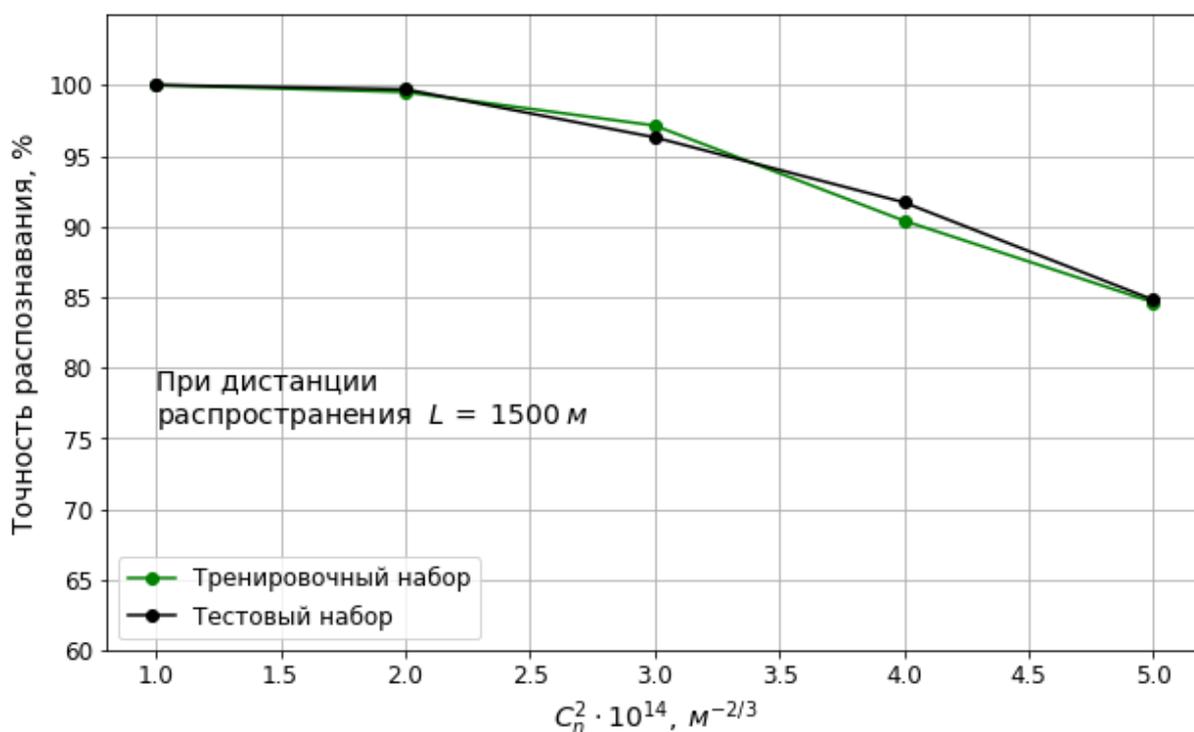


Рисунок 2.1.4 – Зависимость точности распознавания сверточной нейронной сети со слоем глобального взятия среднего от  $C_n^2$  для тренировочного и тестового наборов изображений

Порог распознавания для тестового набора изображений при использовании сверточной нейронной сети с полносвязным слоем составил  $C_{nT}^2 \approx 3.5 \cdot 10^{-14} \text{ м}^{-2/3}$ , а при использовании сверточной нейронной сети со слоем глобального взятия среднего –  $C_{nT}^2 \approx 3.25 \cdot 10^{-14} \text{ м}^{-2/3}$ .

Для оценки работы сверточных нейронных сетей во всем диапазоне силы турбулентности, наблюдаемом в природных условиях, исследованы зависимости точности распознавания от величины структурной характеристики показателя преломления на валидационном наборе данных. Полученные зависимости представлены на рисунках 2.1.5 и 2.1.6.



Согласно рисункам 2.1.5 и 2.1.6 на валидационном наборе изображений при использовании обеих нейронных сетей получены близкие точности распознавания до порогового значения  $C_{nT}^2 \approx 3.5 \cdot 10^{-14} \text{ м}^{-2/3}$ , а при более сильной турбулентности более высокая точность получена при использовании сверточной нейронной сети с полносвязным слоем.

На рисунках 2.1.7 и 2.1.8 приведены зависимости точности распознавания от дистанции распространения пучков для сверточных нейронных сетей с полносвязным слоем и со слоем взятия глобального среднего соответственно.

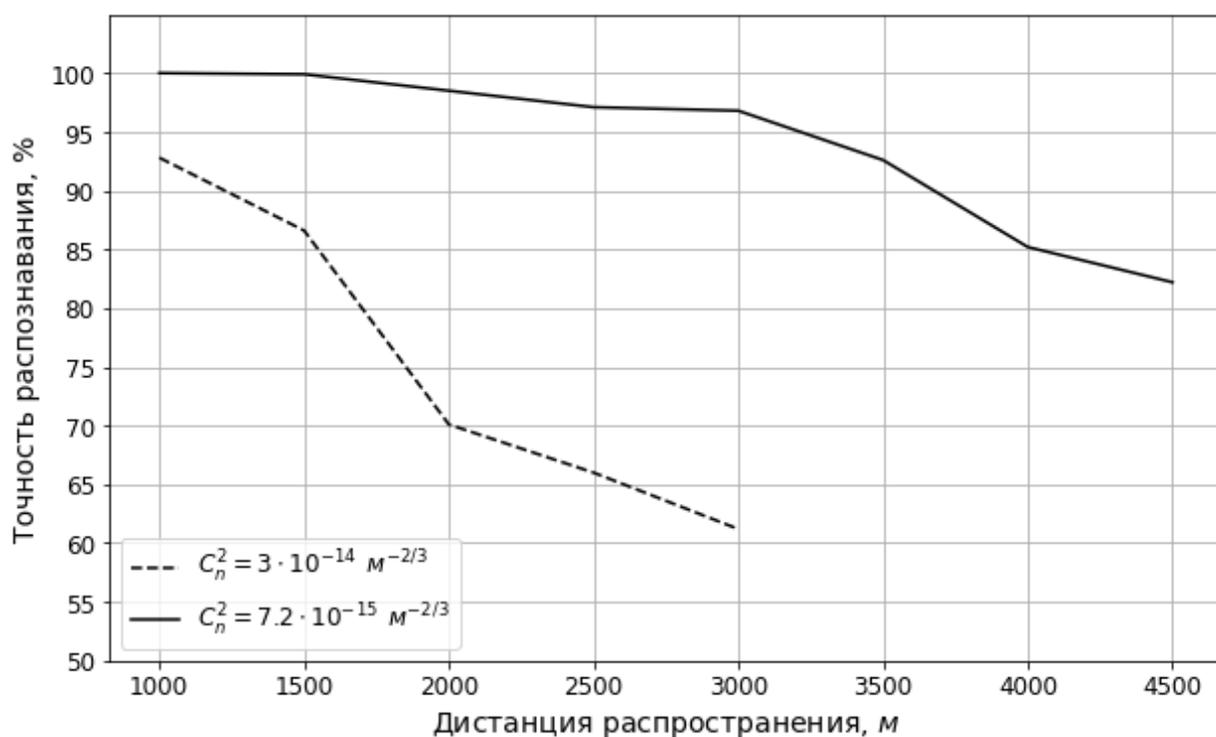


Рисунок 2.1.7 – Зависимость точности распознавания сверточной нейронной сети с полносвязным слоем от дальности распространения пучков для двух уровней турбулентности атмосферы

Согласно рисунку 2.1.7 использование сверточной нейронной сети с полносвязным слоем позволяет получить точность распознавания выше 95 % при  $C_n^2 \approx 7.2 \cdot 10^{-15} \text{ м}^{-2/3}$  в диапазоне дистанций от 1000 м до 3250 м.

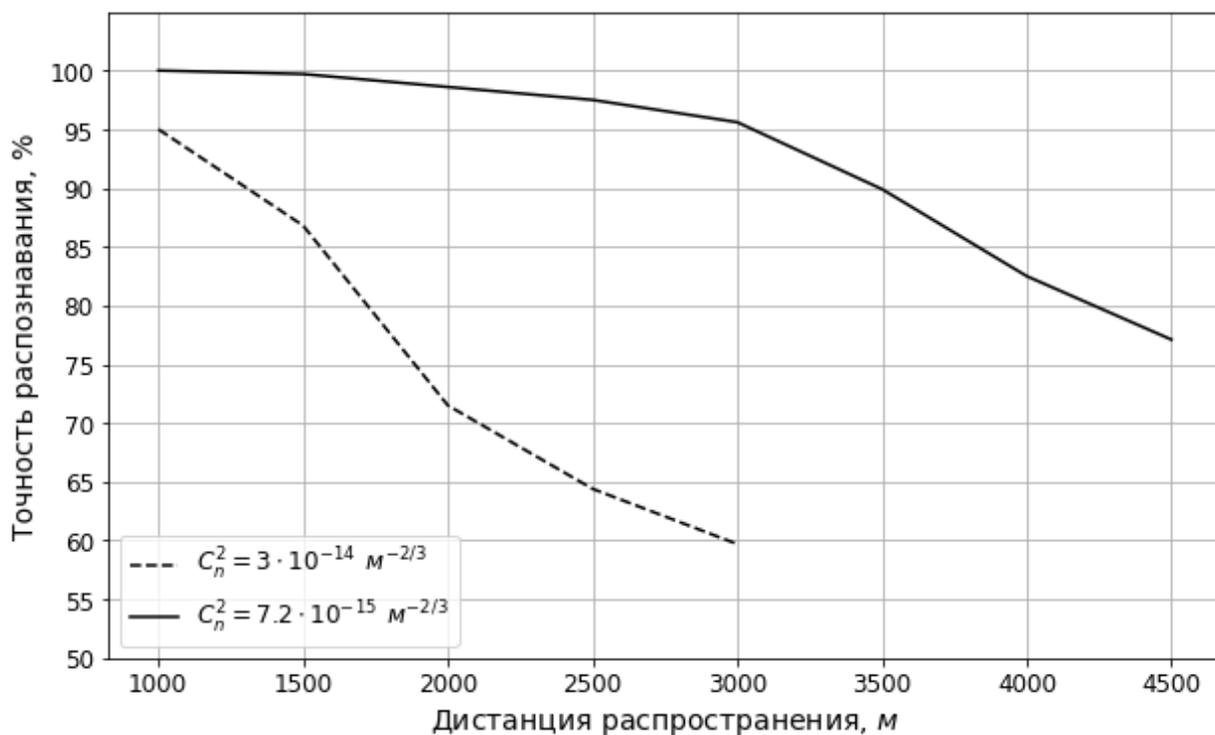


Рисунок 2.1.8 – Зависимость точности распознавания сверточной нейронной сети со слоем глобального взятия среднего от дальности распространения пучков для двух уровней турбулентности атмосферы

Использование сверточной нейронной сети со слоем глобального взятия среднего позволило достичь точности распознавания выше 95 % при  $C_n^2 \approx 7.2 \cdot 10^{-15} \text{ м}^{-2/3}$  в диапазоне дистанций от 1000 м до 3000 м.

При  $C_n^2 \approx 3 \cdot 10^{-14} \text{ м}^{-2/3}$  использование сверточной нейронной сети со слоем глобального взятия среднего позволило получить более высокую точность, но использование обеих сверточных нейронных сетей не позволило получить точность распознавания выше порогового значения 95 % на всех рассматриваемых дистанциях распространения.

## 2.2. Применение остаточных нейронных сетей

На рисунках 2.2.1 и 2.2.2 приведены рассматриваемые в работе архитектуры остаточных нейронных сетей. На рисунке 2.2.3 приведена схема используемого остаточного блока.



Рисунок 2.2.1 – Архитектура остаточной нейронной сети со слоем глобального взятия среднего

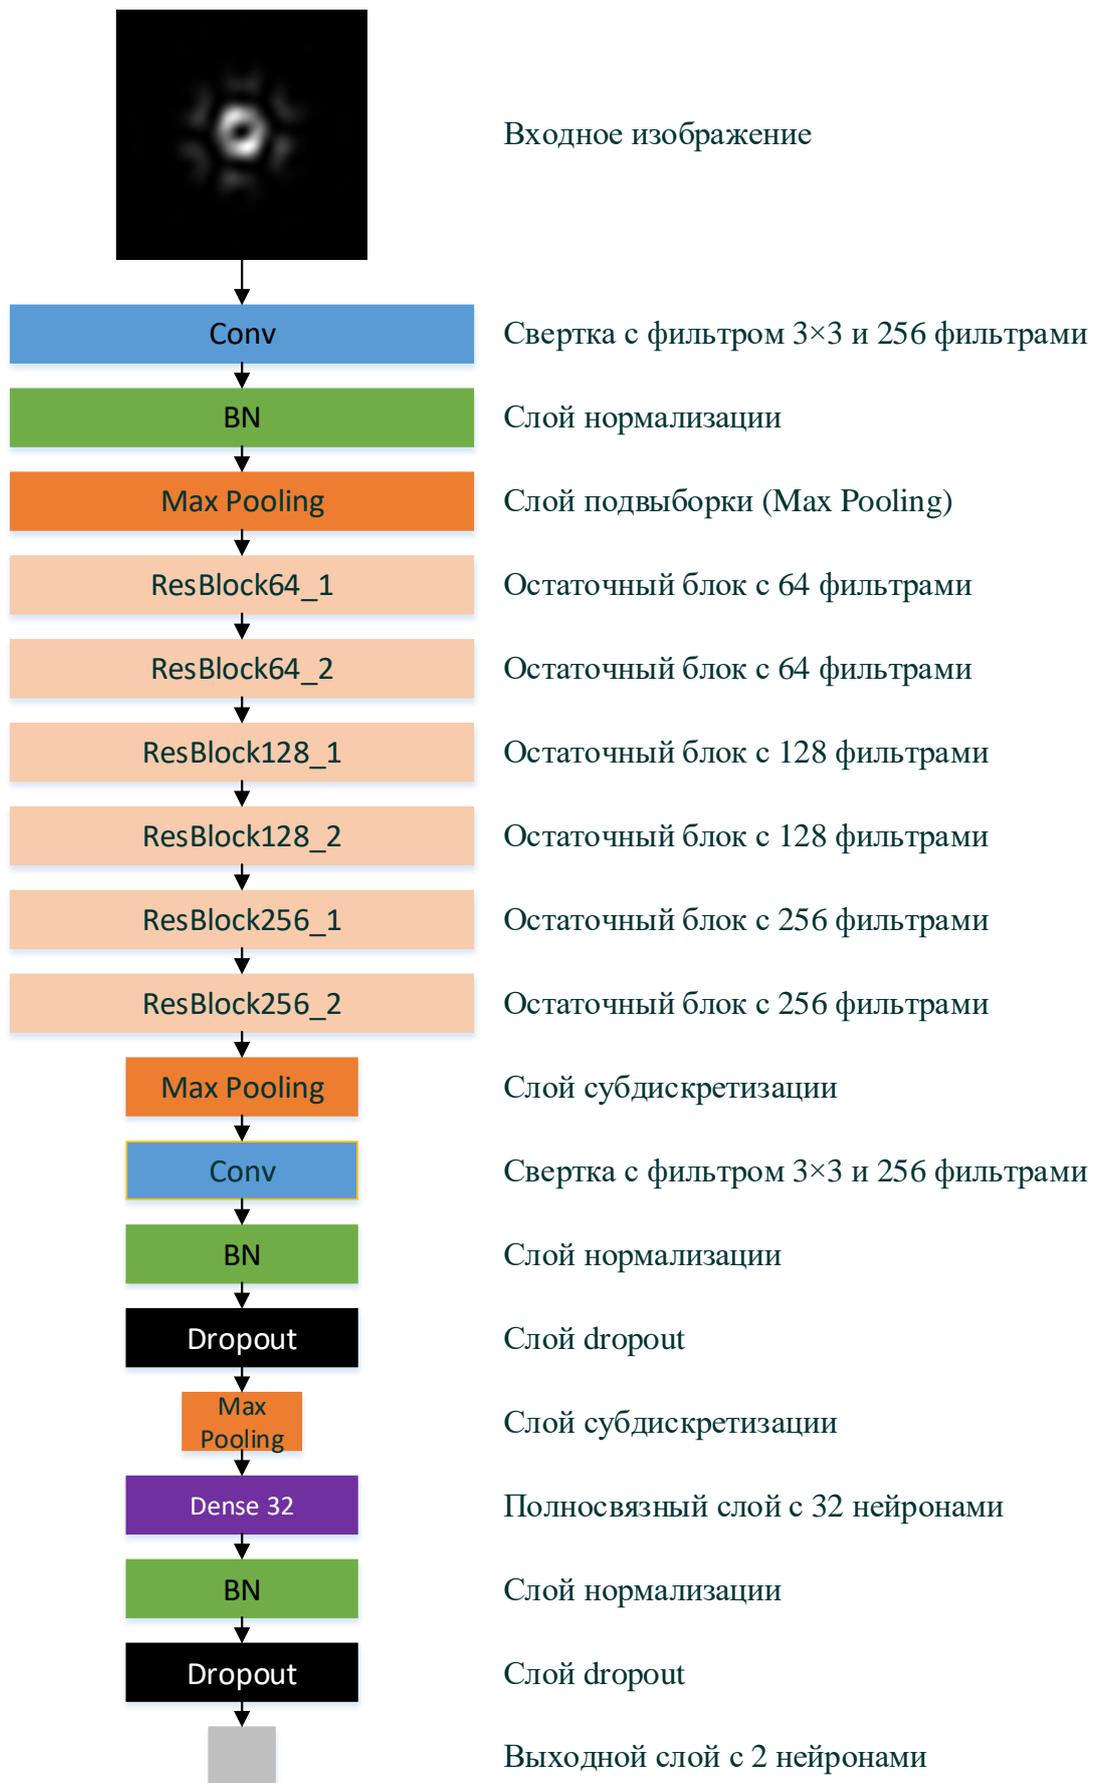


Рисунок 2.2.2 – Архитектура остаточной нейронной сети с полносвязным слоем

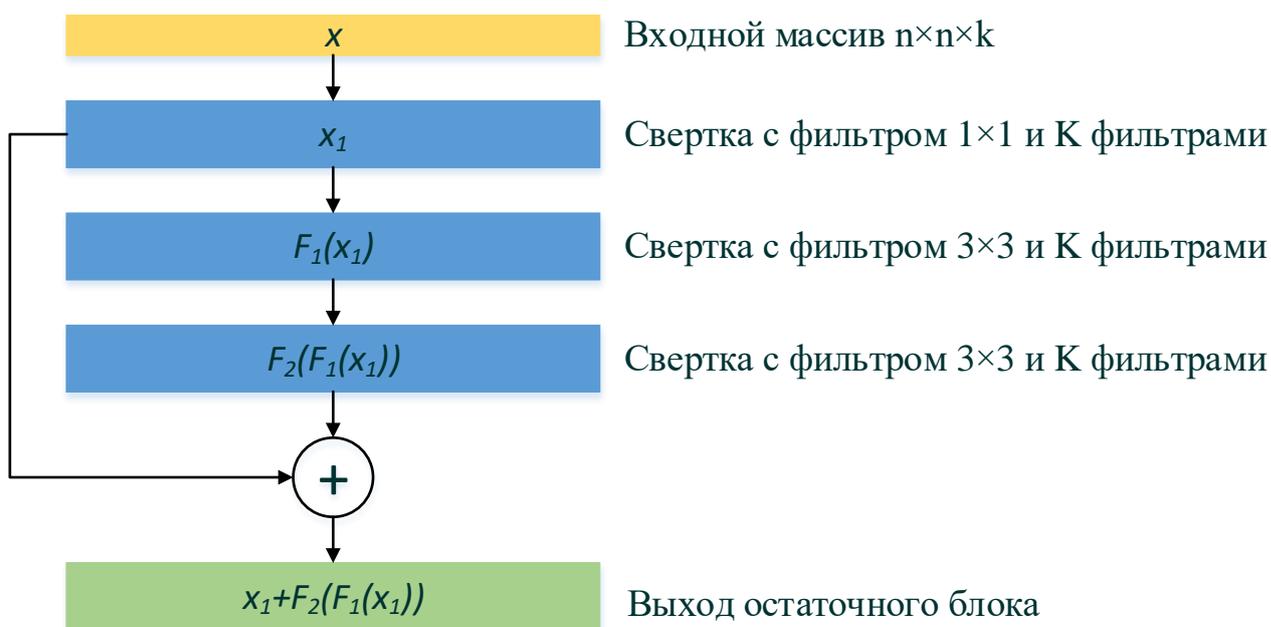


Рисунок 2.2.3 – Остаточный блок, используемый в архитектурах остаточных нейронных сетей

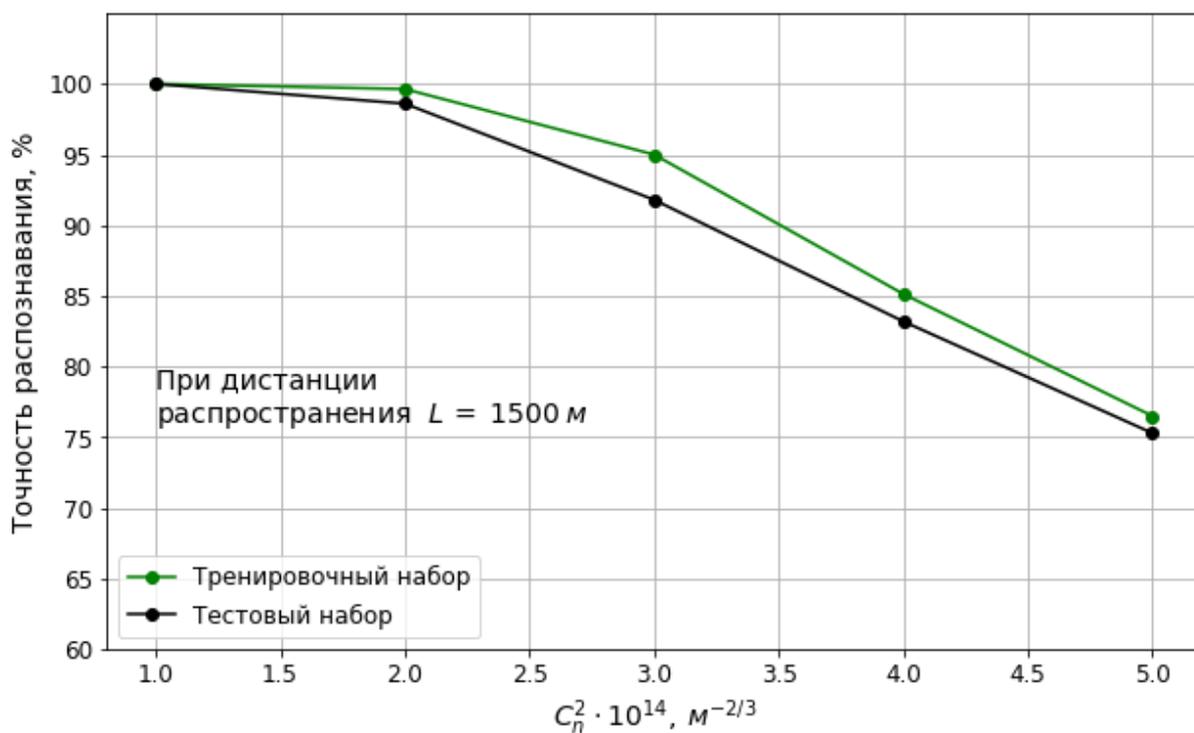


Рисунок 2.2.4 – Зависимость точности распознавания остаточной нейронной сети с полносвязным слоем от  $C_n^2$  для тренировочного и тестового наборов изображений

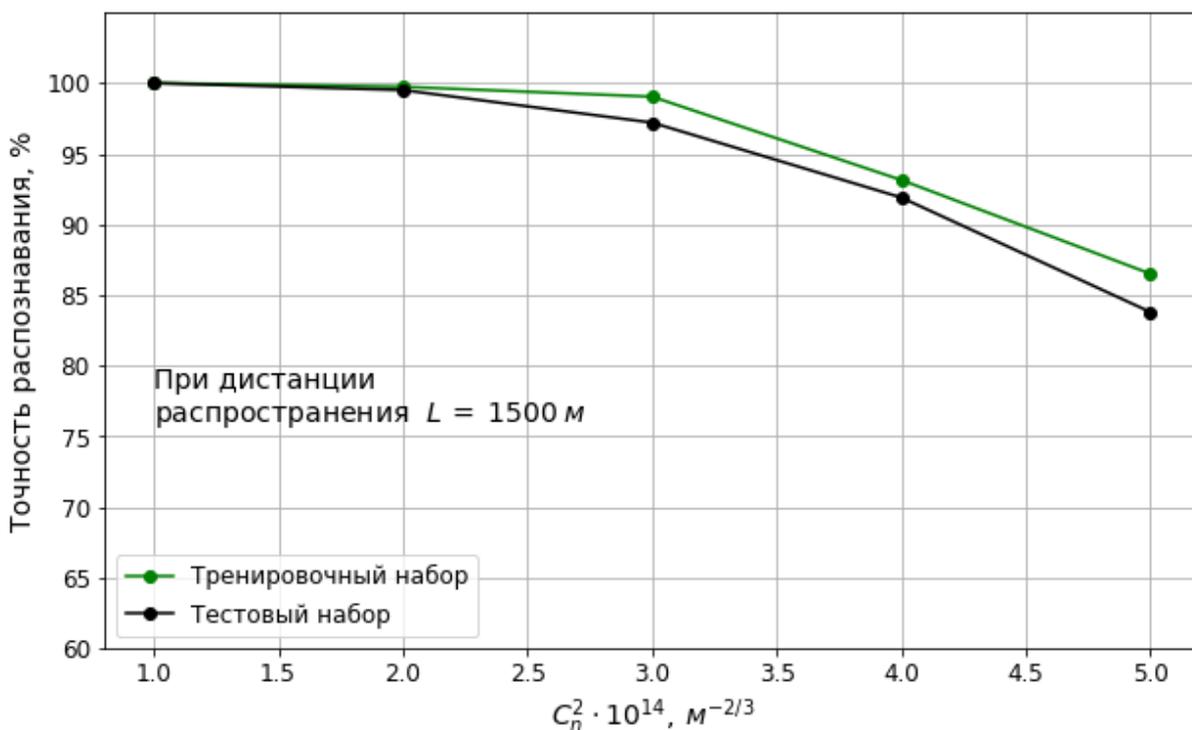


Рисунок 2.2.5 – Зависимость точности распознавания остаточной нейронной сети со слоем глобального взятия среднего от  $C_n^2$  для тренировочного и тестового наборов изображений

На рисунках 2.2.4 и 2.2.5 приведены зависимости точности распознавания остаточной нейронной сети с описанной ранее архитектурой от значения структурной характеристики показателя преломления для всех наборов данных. Согласно зависимостям, использование остаточной нейронной сети со слоем глобального взятия среднего позволило получить более высокую точность распознавания на обучающем наборе. Порог распознавания для тестового набора изображений при использовании остаточной нейронной сети с полносвязным слоем составил  $C_{nT}^2 \approx 2.5 \cdot 10^{-14} \text{ м}^{-2/3}$ , а при использовании остаточной нейронной сети со слоем глобального взятия среднего –  $C_{nT}^2 \approx 3.5 \cdot 10^{-14} \text{ м}^{-2/3}$ .

Для оценки работы остаточных нейронных сетей во всем рассматриваемом диапазоне уровней турбулентности построены зависимости точности распознавания от величины структурной характеристики показателя преломления на валидационном наборе данных. Полученные зависимости представлены на рисунках 2.2.6 и 2.1.7.

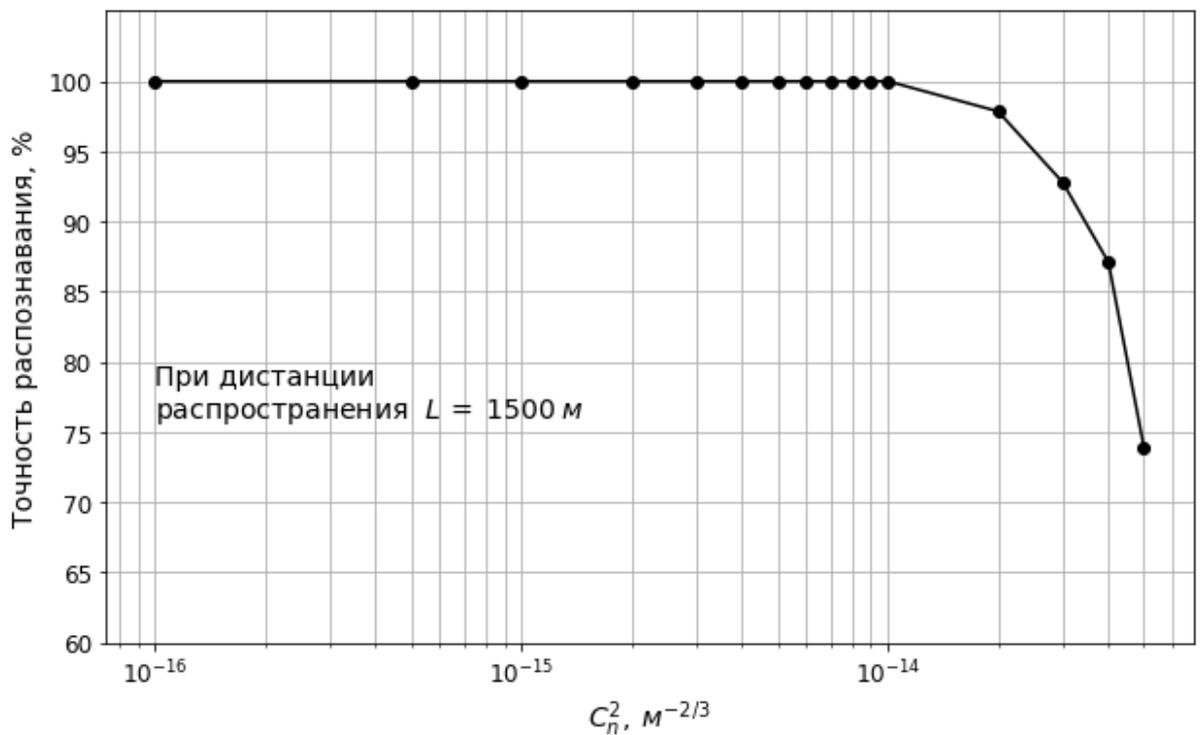


Рисунок 2.2.6 – Зависимость точности распознавания остаточной нейронной сети с полносвязным слоем от  $C_n^2$  для валидационного набора изображений

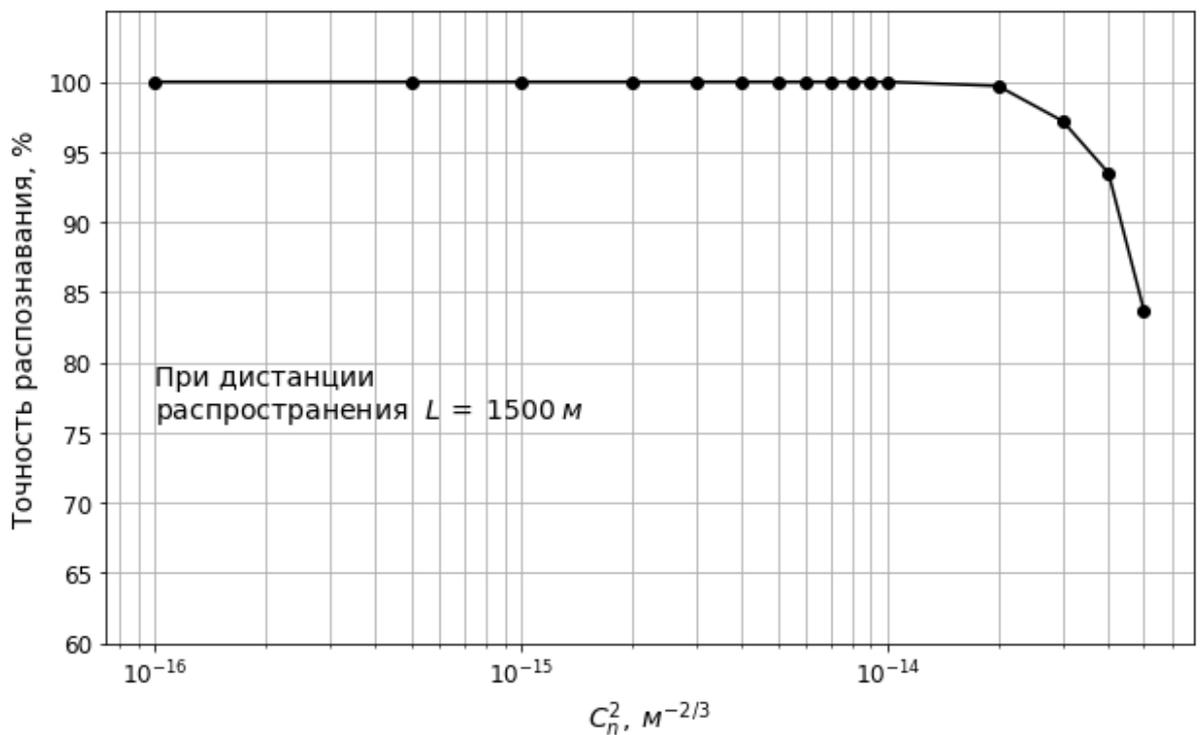


Рисунок 2.2.7 – Зависимость точности распознавания остаточной нейронной сети со слоем глобального взятия среднего от величины  $C_n^2$  для валидационного набора данных

Согласно приведенным зависимостям порог распознавания на валидационном наборе изображений при использовании остаточной нейронной сети с полносвязным слоем составил  $C_{nT}^2 \approx 2.5 \cdot 10^{-14} \text{ м}^{2/3}$ , а при использовании остаточной нейронной сети со слоем глобального взятия среднего –  $C_{nT}^2 \approx 3.5 \cdot 10^{-14} \text{ м}^{2/3}$ .

На рисунках 2.2.8 и 2.2.9 представлены зависимости точности распознавания от дальности распространения пучков для остаточных нейронных сетей с полносвязным слоем и со слоем глобального взятия среднего соответственно.

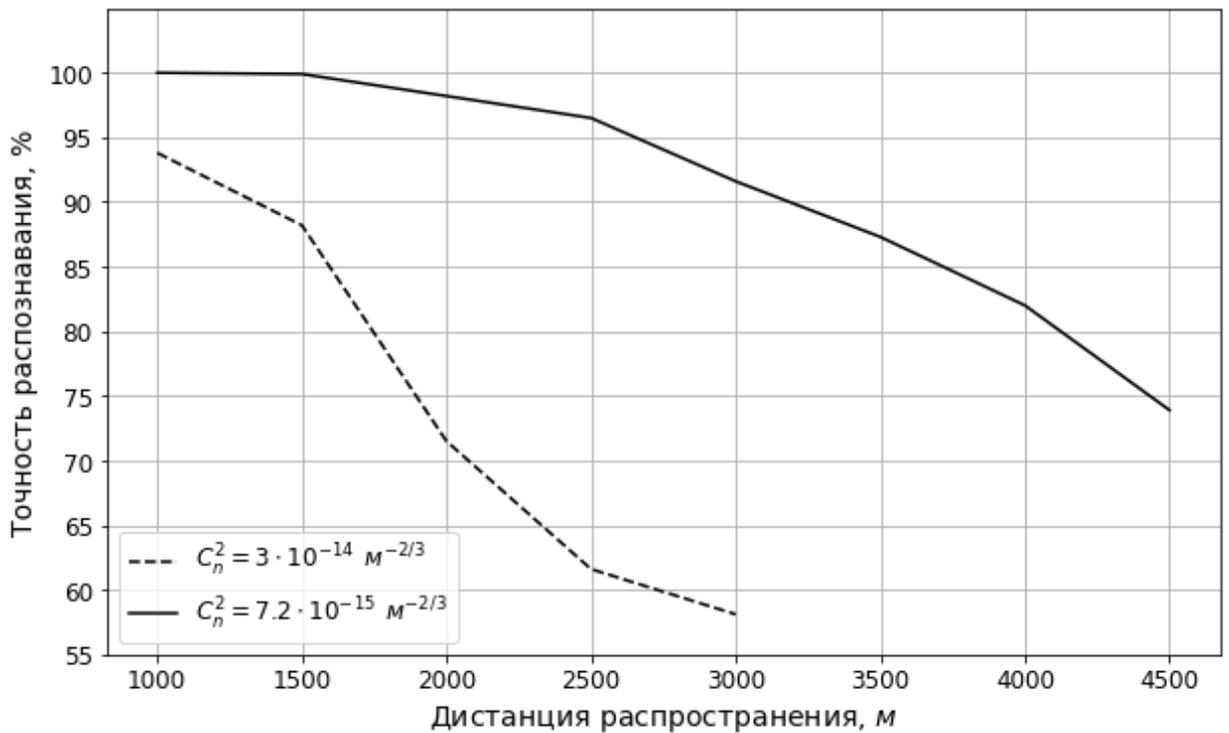


Рисунок 2.2.8 – Зависимость точности распознавания остаточной нейронной сети с полносвязным слоем от дальности распространения пучков для двух уровней турбулентности атмосферы

Согласно рисунку 2.2.8 использование остаточной нейронной сети с полносвязным слоем позволяет получить точность выше 95 % при  $C_n^2 \approx 7.2 \cdot 10^{-15} \text{ м}^{-2/3}$  на дистанциях распространения от 1000 до 2700 м.

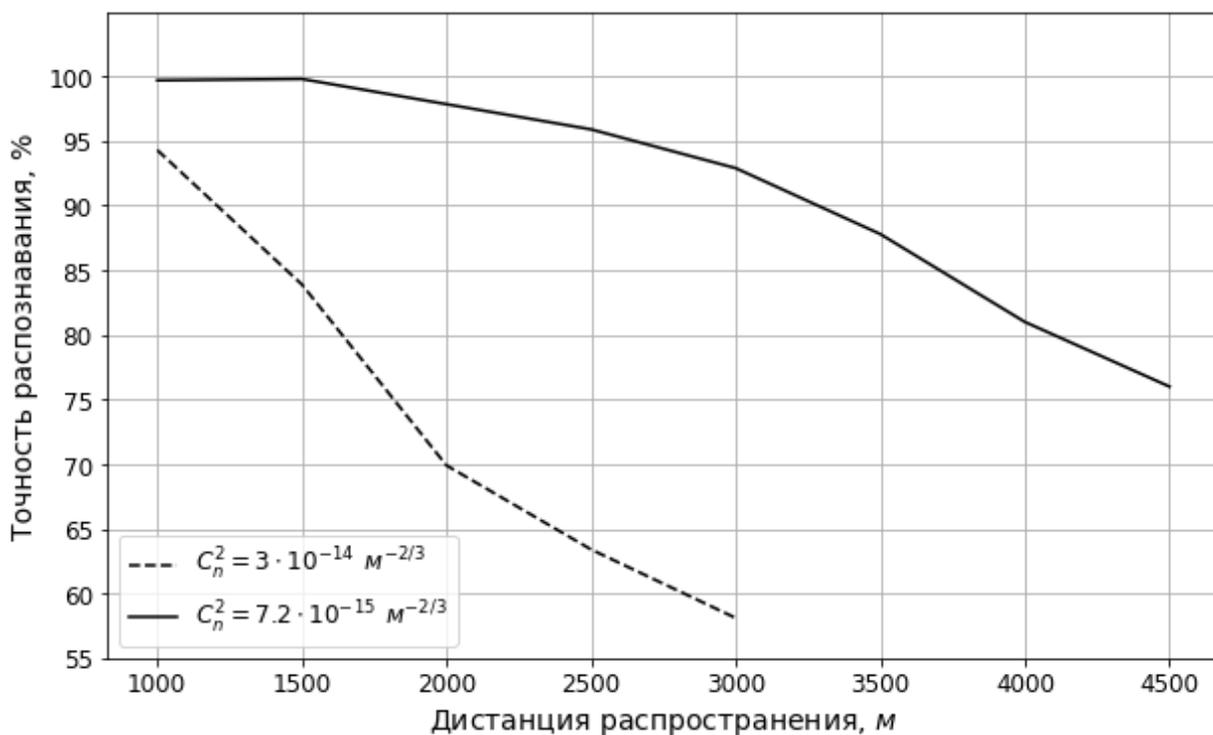


Рисунок 2.2.9 – Зависимость точности распознавания остаточной нейронной сети со слоем глобального взятия среднего от дальности распространения пучков для двух уровней турбулентности атмосферы

Согласно приведенной на рисунке 2.2.8 зависимости применение остаточной нейронной сети с полносвязным слоем и остаточной нейронной сети со слоем глобального взятия среднего позволило получить точность выше 95 % при  $C_n^2 \approx 7.2 \cdot 10^{-15} \text{ м}^{-2/3}$  на дистанциях распространения от 1000 до приблизительно 2700 м. При  $C_n^2 \approx 3 \cdot 10^{-14} \text{ м}^{-2/3}$  использование двух вариантов нейронных сетей не позволяет достичь высокой точности распознавания.

Полученные диапазоны силы турбулентности, в которых использование сверточных и остаточных нейронных сетей позволяет достичь точности распознавания выше 95 %, характеризуют порядка 90 % всех природных атмосферных явлений, что позволяет считать нейронные сети эффективными. Такой широкий диапазон турбулентности позволит использовать нейронные сети для формирования устойчивых к турбулентности атмосферы систем лазерной связи.

### 2.3. Применение альтернативных методов

Одним из классических методов распознавания изображений является метод корреляции изображений. Распознавания 0 и 1 значения ОУМ этим методом можно описать следующим образом:

- рассчитывается взаимная корреляция входного изображения с образцом для 0 значения ОУМ и с образцом для 1 значения ОУМ;
- сравниваются полученные коэффициенты корреляции и формируется результат распознавания: результатом будет то значение ОУМ, образец которого имеет наибольший коэффициент корреляции с входным изображением.

Образцами в этом случае являются распределения интенсивности, полученные при распространении в отсутствии турбулентных искажений. При этом взаимная корреляция изображений с образцом рассчитывается по формуле 2.3.1 [33,34].

$$r_{i,j} = \frac{\sum_{m=0}^M \sum_{n=0}^N (I_{i+m,j+n} - \bar{I})(t_{m,n} - \bar{t})}{\sqrt{\sum_{m=1}^M \sum_{n=1}^N (I_{i+m,j+n} - \bar{I})^2} \sqrt{\sum_{m=1}^M \sum_{n=1}^N (t_{m,n} - \bar{t})^2}}, \quad (2.3.1)$$

где  $r_{i,j}$  – коэффициент корреляции в точке  $i, j$  изображения  $I$  с образцом  $t$ ;

$\bar{I}$  – среднее значение интенсивности пикселей изображения в области, которая покрывается образцом;

$\bar{t}$  – среднее значение интенсивности пикселей образца;

$M, N$  – размеры образца.

На рисунке 2.3.1 приведена зависимость точности распознавания от величины структурной характеристики показателя преломления  $C_n^2$ , а на рисунке 2.3.2 представлена зависимость точности распознавания. Так как данный метод не требует обучения, приведена зависимость только для валидационного набора изображений.

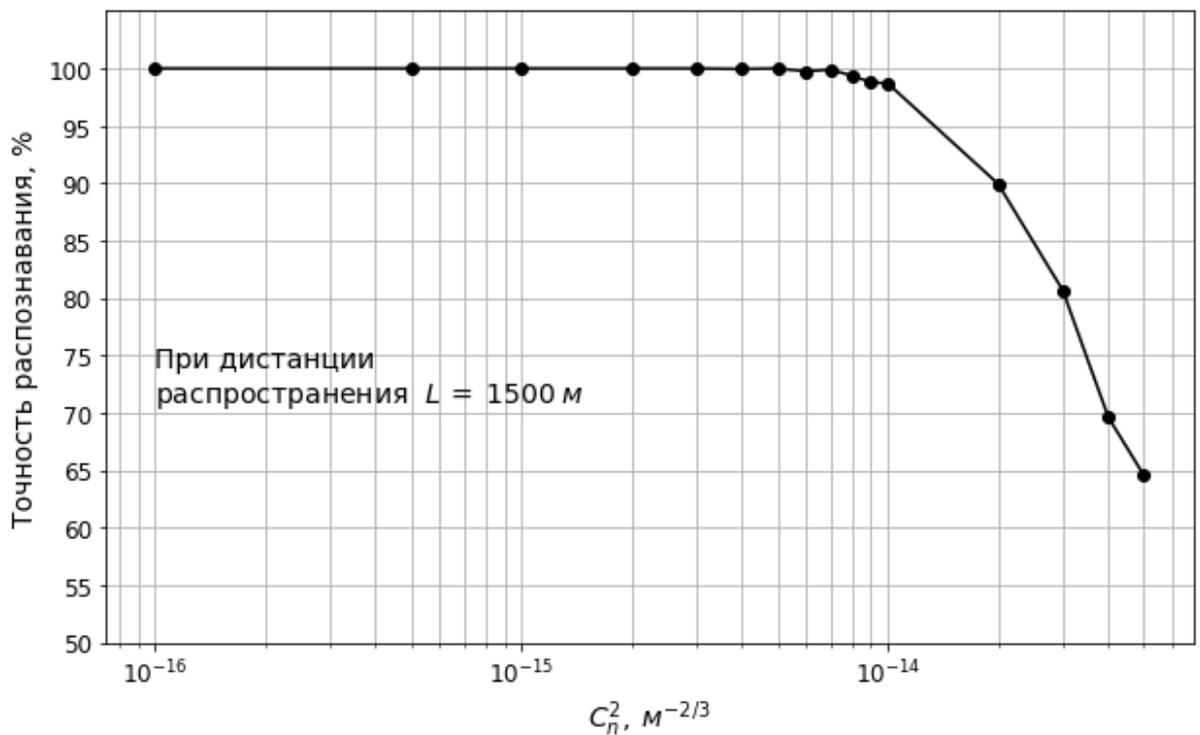


Рисунок 2.3.1 – Зависимость точности распознавания ОУМ методом корреляции изображений от  $C_n^2$

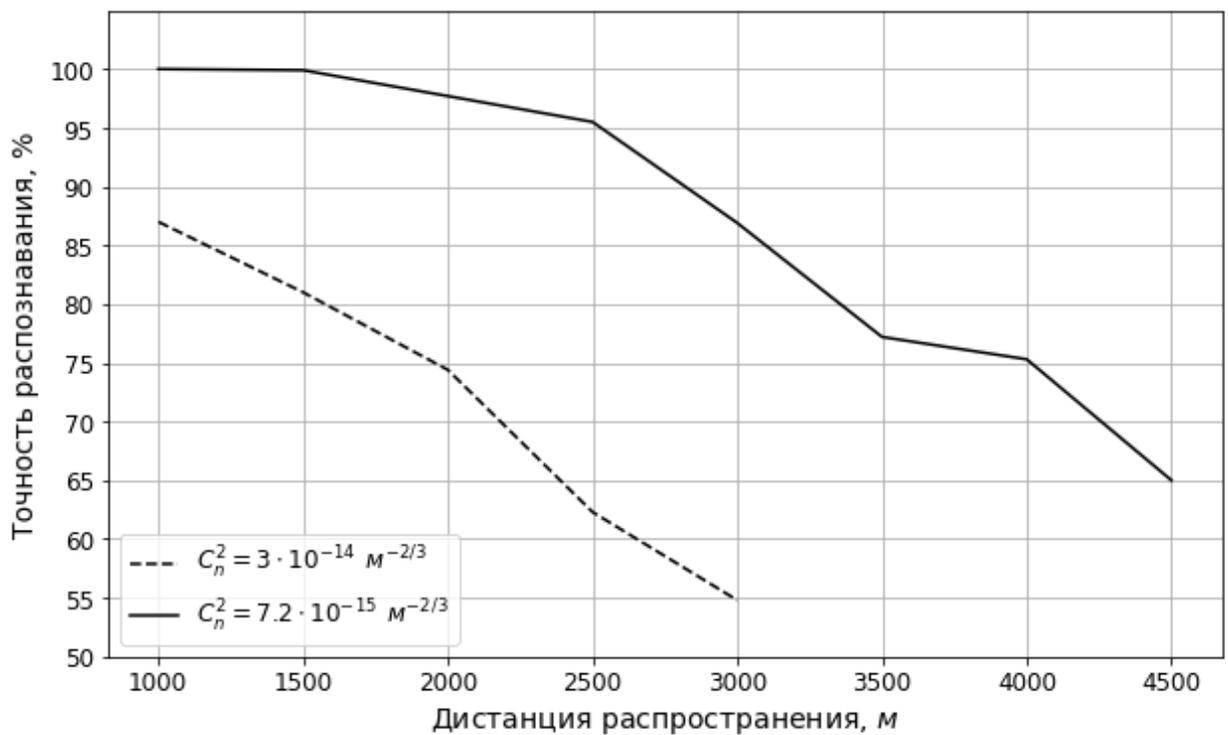


Рисунок 2.3.2 – Зависимость точности распознавания метода корреляции изображения от дальности распространения пучков для двух уровней турбулентности атмосферы

Согласно рисунку 2.3.1 порог распознавания при использовании метода корреляции изображений на валидационном наборе изображений составил  $C_{nT}^2 \approx 1.3 \cdot 10^{-14} \text{ м}^{-2/3}$ .

Согласно приведенной зависимости, диапазон дистанций, в которых при использовании метода корреляции изображений точность распознавания превышает 95 %, при  $C_n^2 \approx 7.2 \cdot 10^{-15}$  составил от 1000 м до 2500 м, а при  $C_n^2 \approx 3 \cdot 10^{-14}$  – на дистанции распространения 1000 м.

В качестве классического метода машинного обучения было принято использовать ансамблевый метод XGBoost [28]. XGBoost – метод машинного обучения, в котором используется градиентный бустинг [35] деревьев.

В качестве входных признаков было принято использовать гистограмму ориентированных градиентов HOG [26,27] для извлечения признаков изображения в векторном представлении. В HOG для извлечения признаков задается размер ячейки, на которые делится изображение. Так как изображения, используемые в данной работе имеют размер 250×250 пикселей, для формирования HOG в работе использованы два размера ячеек: 25×25 и 50×50, чтобы в изображении помещалось целочисленное количество ячеек и использовалась информация обо всем изображении.

Наиболее высокую точность распознавания на тестовом наборе удалось получить с использованием следующих моделей классификатора XGBoost:

- классификатор XGBoost с 256 деревьями и с максимальной глубиной деревьев равной 16 для размера ячейки 50×50;
- классификатор XGBoost с 256 деревьями и с максимальной глубиной деревьев равной 16 для размера ячейки 25×25.

На рисунках 2.3.3 и 2.3.4 приведены зависимости точности распознавания от величины структурной характеристики показателя преломления  $C_n^2$  для различных наборов изображений для размеров ячеек 50×50 и 25×25 соответственно.

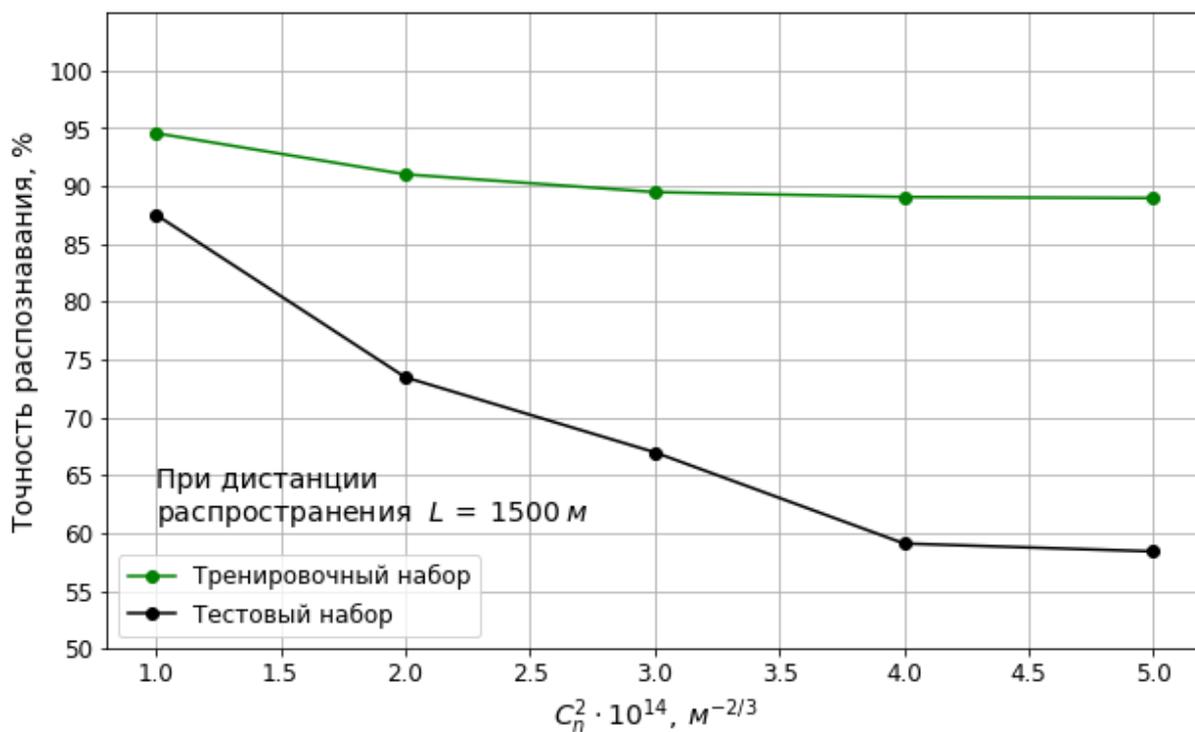


Рисунок 2.3.3 – Зависимость точности распознавания модели XGBoost от  $C_n^2$  для тренировочного и тестового наборов изображений при размере ячеек  $50 \times 50$

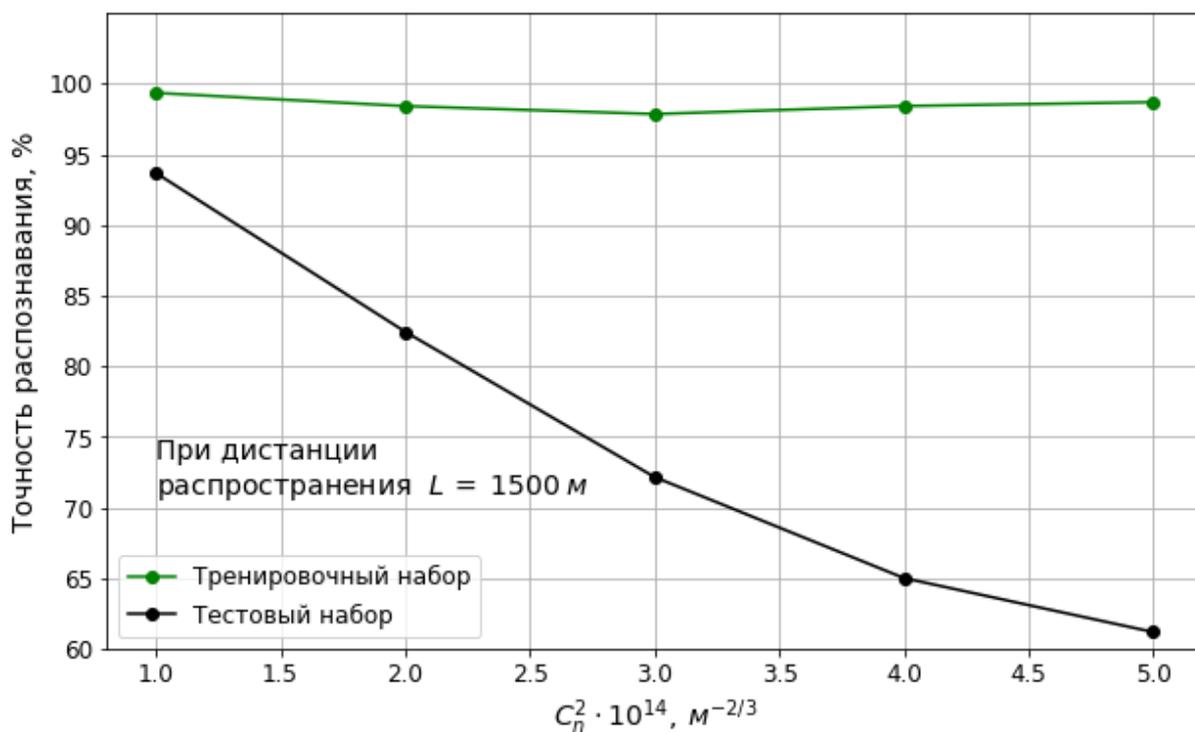


Рисунок 2.3.4 – Зависимость точности распознавания модели XGBoost от  $C_n^2$  для тренировочного и тестового наборов изображений при размере ячеек  $25 \times 25$

Согласно рисунку 2.3.3 точность распознавания при использовании модели с размером ячеек «НОГ» равным  $50 \times 50$  на тестовом множестве очень быстро падает с ростом  $C_n^2$  и не превышает 95 % на всем диапазоне уровней турбулентности для тестового набора.

Согласно рисунку 2.3.4 точность распознавания при использовании модели с размером ячеек «НОГ» равным  $25 \times 25$  на тестовом наборе изображений быстро падает с ростом турбулентности и близка к порогу распознавания только при  $C_{nT}^2 = 1 \cdot 10^{-14} \text{ м}^{-2/3}$ .

Для оценки работы моделей распознавания на основе XGBoost на всем рассматриваемом диапазоне уровней турбулентности построены зависимости точности распознавания от величины структурной характеристики показателя преломления на валидационном наборе данных. Полученные зависимости для размеров ячеек  $50 \times 50$  и  $25 \times 25$  представлены на рисунках 2.3.5 и 2.3.6.

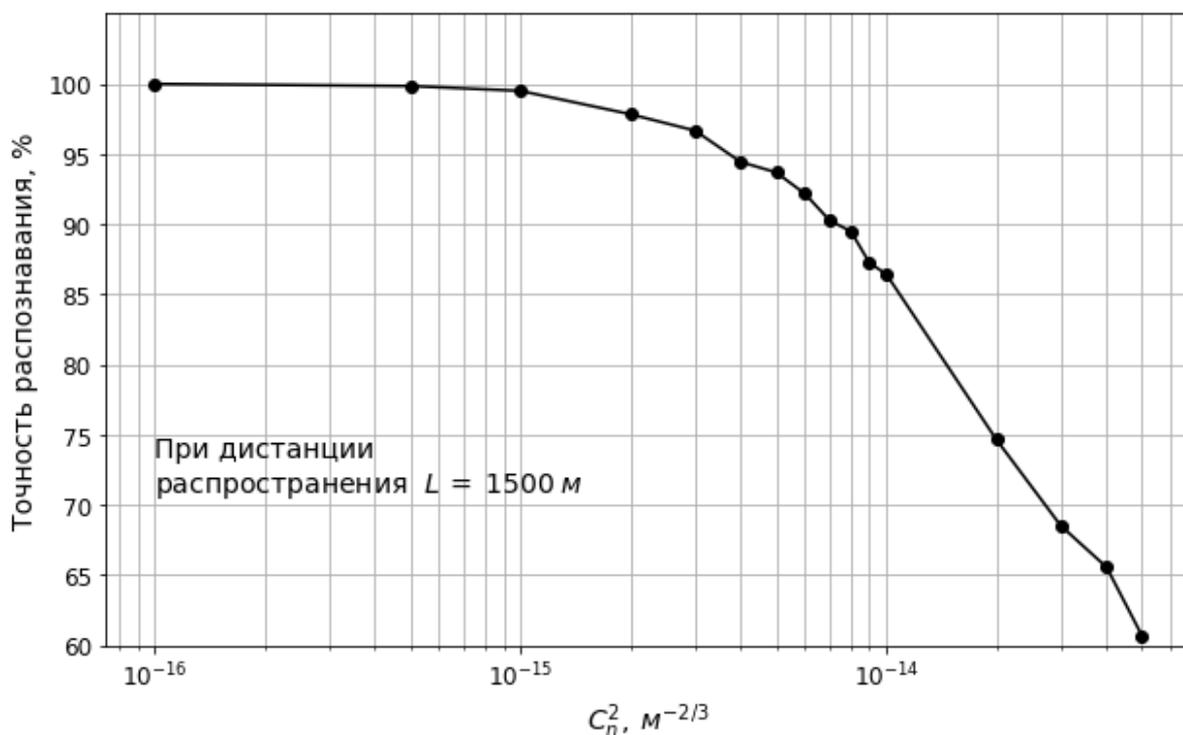


Рисунок 2.3.5 – Зависимость точности распознавания модели «XGBoost» от  $C_n^2$  для валидационного набора изображений при размере ячеек  $50 \times 50$

Использование модели с размером ячеек «НОГ» равным  $50 \times 50$  позволяет получить высокую точность при слабой турбулентности, а при среднем уровне

турбулентности точность распознавания модели начинает быстро падать. Порог распознавания для модели с размером ячеек  $50 \times 50$  составил  $C_{nT}^2 \approx 4 \cdot 10^{-15} \text{ м}^{-2/3}$ .

Такие низкие показатели модели с размером ячеек  $50 \times 50$  показывают, что использование «НОГ» является излишним и не позволяет получить высокую точность распознавания.

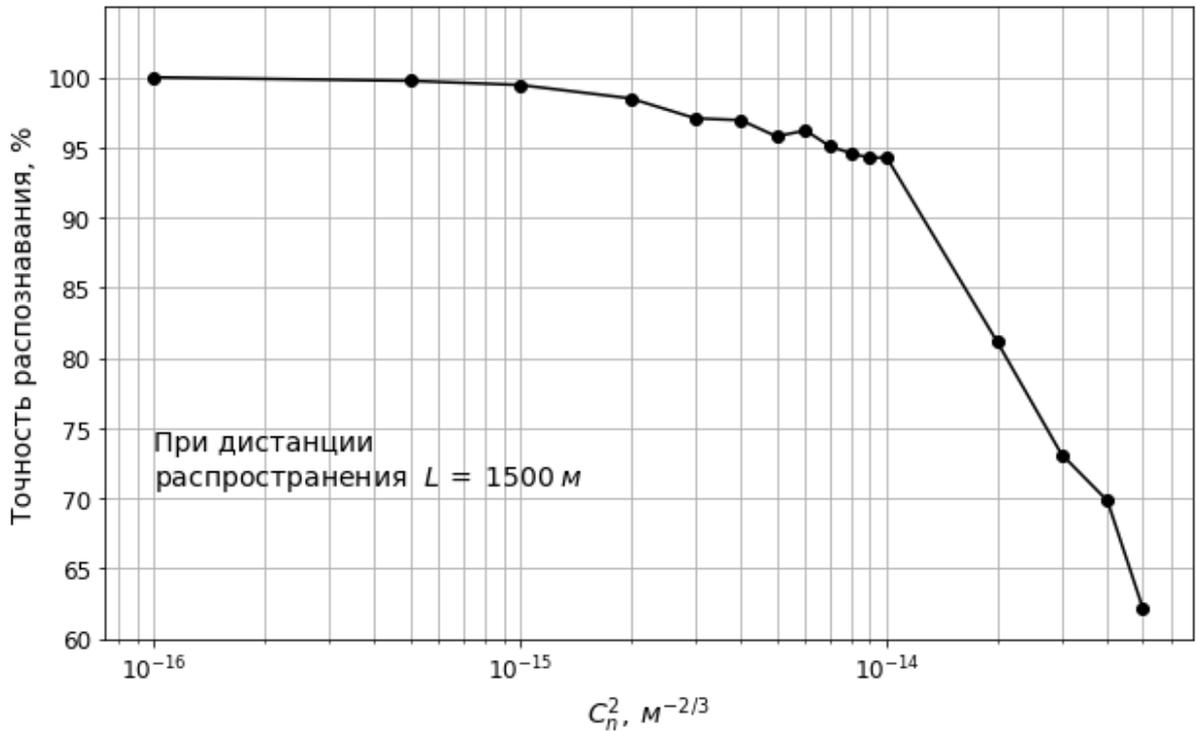


Рисунок 2.3.6 – Зависимость точности распознавания модели «XGBoost» от  $C_n^2$  для валидационного набора изображений при размере ячеек  $25 \times 25$

Согласно зависимости, представленной на рисунке 2.3.5, использование модели с размером ячеек «НОГ»  $25 \times 25$  позволяет получить точность распознавания выше 95 % на валидационном наборе изображений на промежутке значений  $C_n^2 \in (1 \cdot 10^{-16}; 1 \cdot 10^{-14}) \text{ м}^{-2/3}$ . Порог распознавания для данной модели составил  $C_{nT}^2 \approx 1 \cdot 10^{-14} \text{ м}^{-2/3}$ . Использование модели с размером ячеек  $25 \times 25$  позволяет получить более высокую точность распознавания, в сравнении с использованием модели с размером ячеек  $50 \times 50$ .

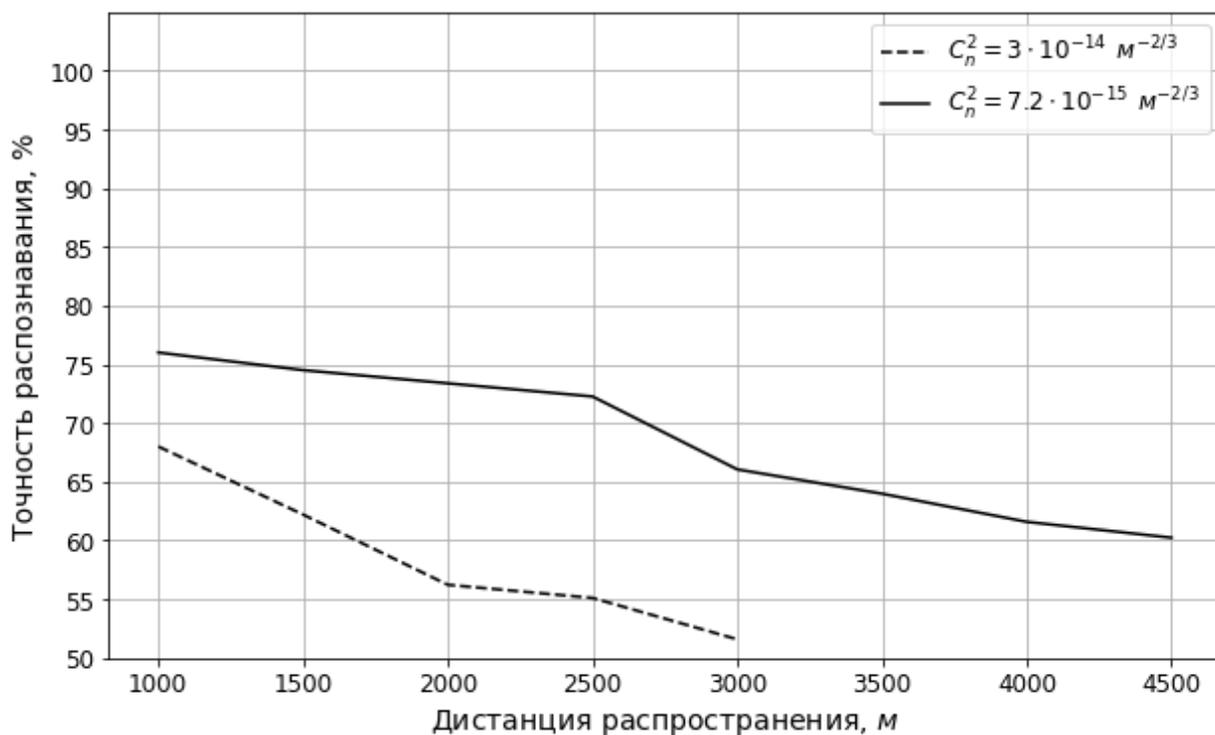


Рисунок 2.3.7 – Зависимость точности распознавания классификатора XGBoost от дальности распространения пучков при размере ячеек 50×50

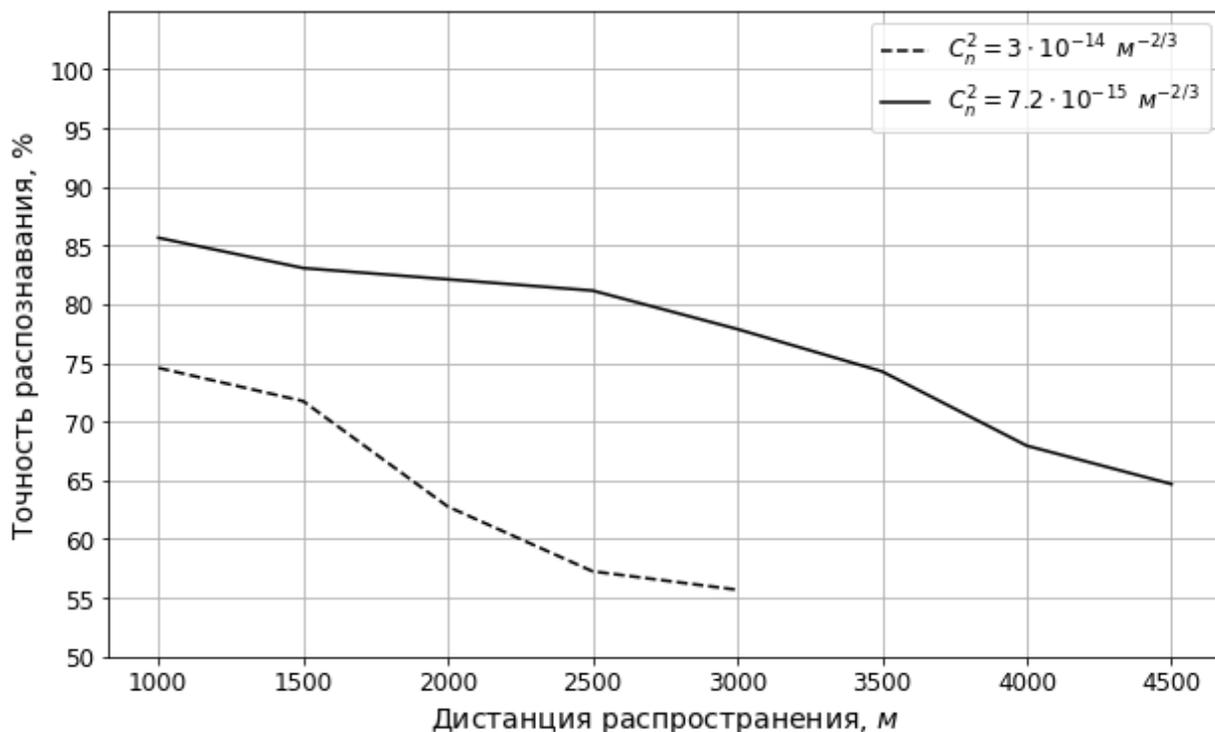


Рисунок 2.3.8 – Зависимость точности распознавания классификатора XGBoost от дальности распространения пучков при размере ячеек 25×25

На рисунках 2.3.7 и 2.3.8 представлены зависимости точности распознавания от дальности распространения пучков для размеров ячеек 50×50 и 25×25 соответственно.

Метод распознавания, основанный на использовании «XGBoost» и «HOG» не позволяет получить точность распознавания выше 95 % на всем рассматриваемом диапазоне дистанций распространения.

Полученные результаты показали, что для задачи распознавания ОУМ по изображениям интенсивности извлечение признаков из изображений и использование метода корреляции изображений не позволило получить высокую точность при сильной турбулентности.

В таблице 2 представлена сравнительная таблица точности распознавания всех рассмотренных в работе моделей.

Таблица 2 – Сравнение рассмотренных моделей

Метод распознавания	Порог распознавания по турбулентности, $m^{-2/3}$	Диапазон точного распознавания по дальности распространения при $C_n^2 = 7.2 \cdot 10^{-15} m^{-2/3}$
Сверточная нейронная сеть с полносвязным слоем	$C_{nT}^2 \approx 3.5 \cdot 10^{-14}$	1000 м – 3250 м
Сверточная нейронная сеть со слоем глобального взятия среднего	$C_{nT}^2 \approx 3.25 \cdot 10^{-14}$	1000 м – 3000 м
Остаточная нейронная сеть с полносвязным слоем	$C_{nT}^2 \approx 3.5 \cdot 10^{-14}$	1000 м – 2700 м
Остаточная нейронная сеть со слоем глобального взятия среднего	$C_{nT}^2 \approx 1 \cdot 10^{-14}$	1000 м – 2700 м
Метод корреляции изображений	$C_{nT}^2 \approx 1.3 \cdot 10^{-14}$	1000 м – 2500 м
Метод «XGBoost» с «HOG» при размере ячеек 25×25	$C_{nT}^2 \approx 1 \cdot 10^{-14}$	–
Метод «XGBoost» с «HOG» при размере ячеек 50×50	$C_{nT}^2 \approx 4 \cdot 10^{-15}$	–

Для дальнейшего сравнения методов выбраны следующие: сверточная нейронная сеть с полносвязным слоем, остаточная нейронная сеть с слоем глобального взятия среднего, «XGBoost» с «HOG» с размером ячеек 25×25 и метод корреляции изображений.

## 2.4. Сравнение эффективности рассмотренных методов

Для сравнения эффективности работы рассмотренных методов построены зависимости точностей распознавания, полученных этими методами на валидационном множестве, от величины структурной характеристики показателя преломления. Построенные зависимости представлены на рисунке 2.4.1.

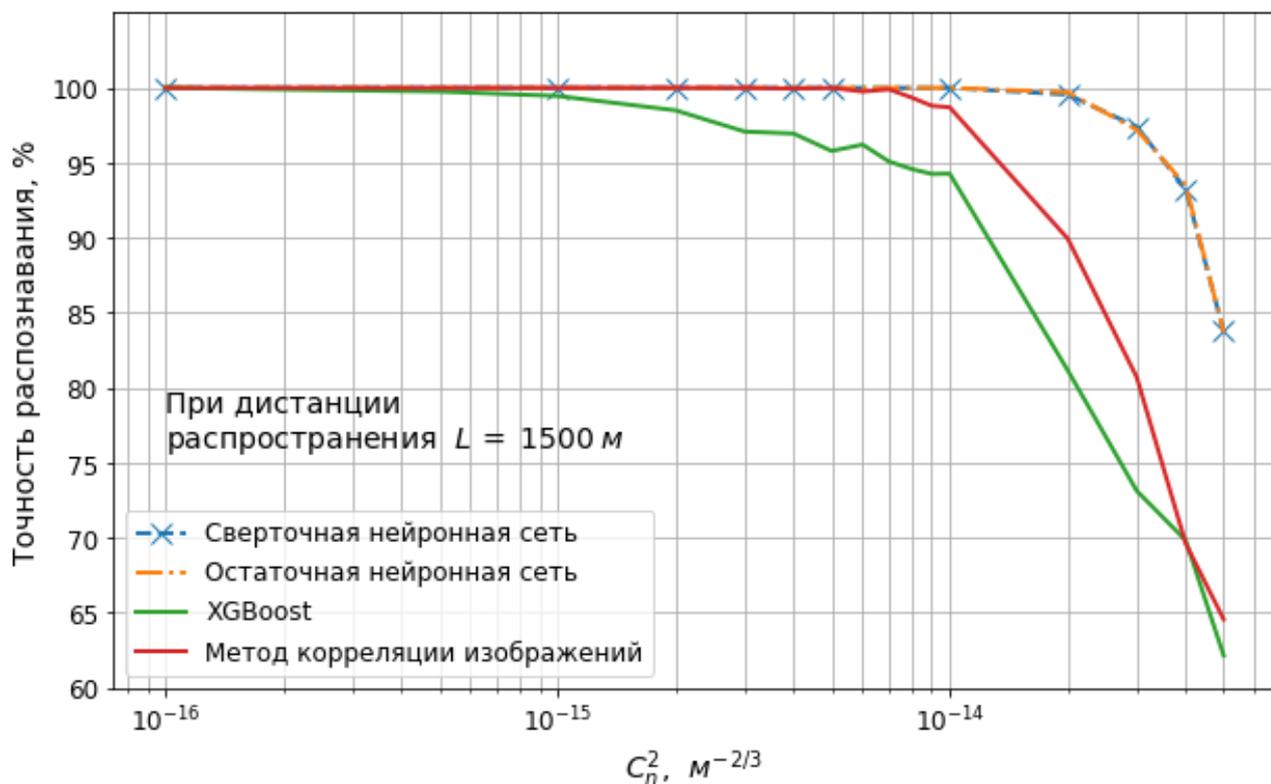


Рисунок 2.4.1 – Зависимость точности распознавания различных методов от величины структурной характеристики показателя преломления

Согласно зависимостям, приведенным на рисунке 2.4.1, использование сверточной и остаточной нейронных сетей позволило получить более высокую точность распознавания в области сильной турбулентности, в сравнении с использованием метода корреляции изображений и «XGBoost». Самую высокую точность удалось получить при использовании сверточной нейронной сети с полносвязным слоем и остаточной нейронной сети со слоем глобального взятия среднего. Порог распознавания при использовании этих сетей составил  $C_{nT}^2 \approx 3.5 \cdot 10^{-14} \text{ м}^{-2/3}$ . Промежуток значений структурной характеристики

показателя преломления, в которых использование нейронных сетей позволяет получить точность распознавания выше 95 % характеризует около 90 % всех атмосферных явлений, встречаемых в природе [35]. В приложении Б представлены матрицы неточностей для всех рассмотренных методов.

На рисунке 2.4.2 представлены зависимости точности распознавания от дальности распространения всех рассмотренных методов при  $C_n^2 \approx 7.2 \cdot 10^{-15} \text{ м}^{-2/3}$ .

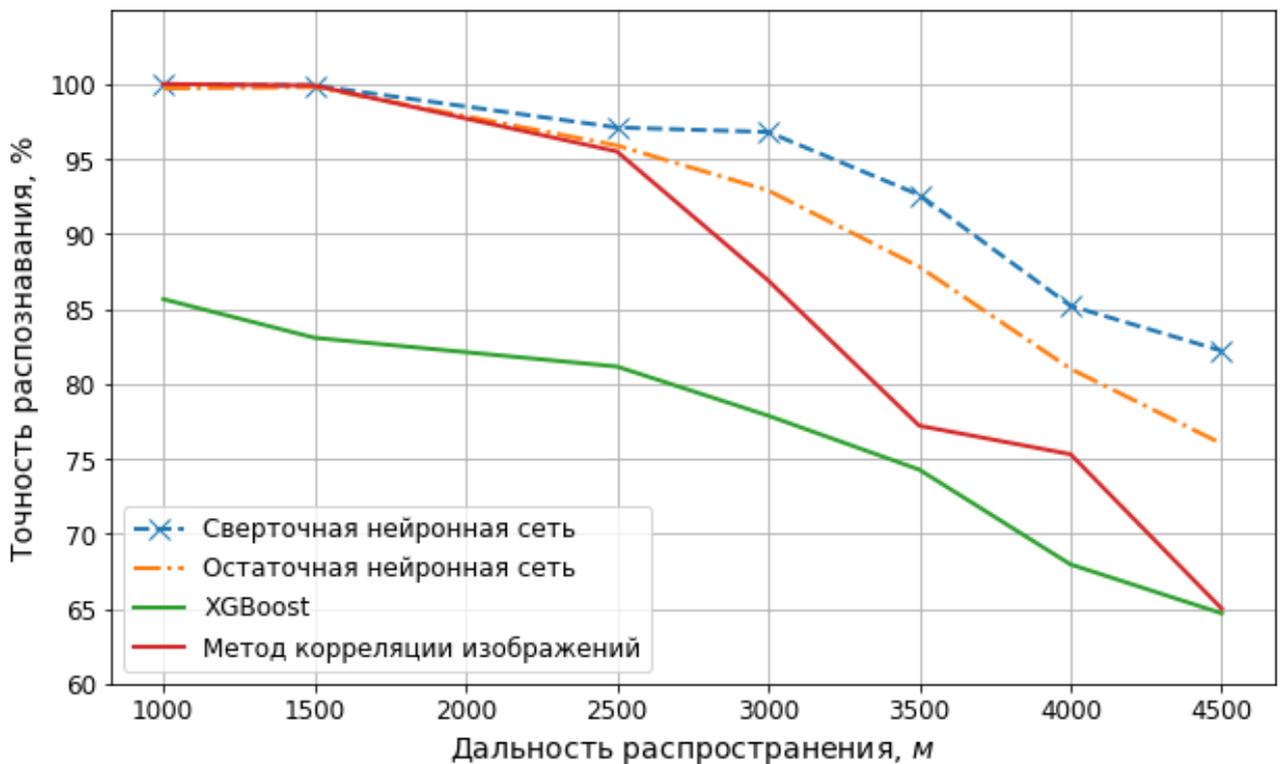


Рисунок 2.4.2 – Зависимость точности распознавания различных методов от дальности распространения пучков

Согласно приведенным зависимостям, наибольший диапазон дистанций, при которых точность распознавания превышает 95 %, охватывают нейронные сети: использование сверточной нейронной сети с полносвязным слоем позволяет получить такую точность распознавания на дистанции до 3250 м, а при использовании остаточной нейронной сети со слоем глобального взятия среднего – до 2700 м.

### **3. Финансовый менеджмент, ресурсоэффективность и ресурсосбережение**

В настоящее время перспективность научно-исследовательского проекта определяет не только масштаб открытия, провести достаточно точную оценку которого в начале жизненного цикла продукта не всегда удастся, но и коммерческая ценность разработки. Для поиска источников финансирования проведения научного исследования и коммерциализации его результатов необходимым условием является оценка коммерческой ценности (или потенциала) разработки. Проведение такой оценки способствует поиску партнеров для дальнейших исследований, коммерциализации результатов текущего исследования и открытию бизнеса [37].

Коммерческую привлекательность научного исследования определяет не только превышениями технических параметров продукта исследования в сравнении с предыдущими разработками, но и то, насколько объективную и своевременную оценку разработчик может дать коммерческим перспективам проекта – востребованность продукта на рынке, наиболее удовлетворяющая потребителя и приносящая прибыль цена, необходимый бюджет проекта, необходимое для выхода на рынок время и так далее.

Целью раздела «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение» является определение перспективности и успешности научно-исследовательского проекта «Применение нейронных сетей для распознавания распределений интенсивности лазерных пучков, обладающих различными значениями орбитального углового момента и распространяющихся через турбулентную атмосферу».

Достижение заявленной цели обеспечено решением следующих задач:

– определение потенциальных потребителей результатов проведенного исследования;

- проведение SWOT-анализа для выявления и оценки сильных и слабых сторон научно-исследовательского проекта, его возможностей и вероятных угроз;
- оценка готовности научного проекта к коммерциализации;
- выбор метода коммерциализации;
- определение заинтересованных сторон,
- определение целей и ожидаемых результатов проекта;
- определение организационной структуры проекта
- определение ограничений и допущений проекта;
- определение структуры и трудоемкости необходимых к исполнению работ, разработка плана проведения научного исследования;
- формирование диаграммы Ганта;
- расчет всех затрат, необходимых на проведение научно-исследовательского проекта, формирование бюджета проекта.

### **3.1. Предпроектный анализ**

#### **3.1.1. Потенциальные потребители результатов исследования**

Рассмотрение целевого рынка и его сегментирование необходимо для анализа потребителей результатов исследования. В настоящей работе исследовано применение нейронных сетей в качестве решения задачи распознавания ОУМ для создания защищенных каналов связи в условиях работы квантовых компьютеров. Поэтому целевой рынок исследовательского проекта определяется целевым рынком систем безопасной связи, основанных на кодировании информации в значениях ОУМ пучков, распространяющихся в свободной атмосфере.

Целевым рынком таких систем безопасной связи являются компании, использующие в ходе своей деятельности криптографические алгоритмы, что делает их уязвимыми в условиях работы квантовых компьютеров. Этот рынок можно сегментировать по сферам применения криптографических систем и по сферам деятельности компаний. В таблице 3 приведена карта сегментирования

целевого рынка. Результаты настоящего научно-исследовательского проекта могут быть реализованы только в сегменте защищенной передачи данных.

Таблица 3 – Карта сегментирования рынка сфер деятельности компаний по сфере использования криптографических систем

		Сфера применения криптографических систем		
		безопасное хранение данных	защищенная передача данных	цифровые подписи
Сфера деятельности компаний	цифровые банковские системы			
	мессенджеры и электронная почта			
	электронные информационные ресурсы			

### 3.1.2. Анализ конкурентных технических решений

Результаты исследования, проведенного в настоящей работе, имеют конкурентные решения в области способа распознавания ОУМ пучков, распространяющихся в турбулентной атмосфере. Для метода, рассмотренного в настоящей работе и основанного на применении нейронных сетей, существуют следующие конкурентные технические решения:

- применение «классических» математических методов сравнения изображений;
- применение «классического» машинного обучения;
- использование дополнительных оптических систем, позволяющих получить из результирующих картин распределения интенсивности информацию о значении орбитального углового момента.

Проведение оценочного сравнения эффективности научно-исследовательского проекта осуществляется посредством анализа конкурентных технических решений с позиции ресурсоэффективности и ресурсосбережения. В таблице 4 представлена оценочная карта сравнения конкурентных технических решений.

Таблица 4 – Оценочная карта сравнения конкурентных технических решений

Критерии оценки	Вес критерия оценки	Баллы				Способность к конкуренции			
		Бп	Бк1	Бк2	Бк3	Кп	Кк1	Кк2	Кк3
1	2	3	4	5	6	7	8	9	10
Технические критерии ресурсоэффективности									
1. Простота эксплуатации	0.1	5	4	4	3	0.50	0.40	0.40	0.30
2. Автономность	0.1	5	5	5	3	0.50	0.50	0.50	0.30
3. Точность распознавания	0.3	5	4	3	5	1.50	1.20	0.90	1.50
4. Простота перенастройки	0.2	5	1	5	3	1.00	0.20	1.00	0.60
5. Необходимость специального оборудования	0.1	4	5	4	3	0.40	0.50	0.40	0.30
6. Скорость распознавания	0.2	4	3	3	5	0.80	0.60	0.60	1.00
Экономические критерии оценки эффективности									
1. Цена	0.2	5	5	5	3	1.00	1.00	1.00	0.60
2. Срок выхода на рынок	0.25	4	5	5	3	1.00	1.25	1.25	0.75
3. Сопровождающее обслуживание	0.25	5	5	5	4	1.25	1.25	1.25	1.00
4. Финансирование научной разработки	0.3	4	5	4	3	1.20	1.50	1.20	0.90
Итого						9.15	8.40	8.50	7.25

Определение конкурентоспособности определяется следующим выражением:

$$K = \sum_i B_i \cdot B_i \quad (3.1.2.1)$$

где  $K$  – конкурентоспособность;

$B_i$  – вес  $i$ -го показателя;

$B_i$  – балл  $i$ -го показателя.

В результате анализа получены следующие оценки конкурентоспособности:

- рассматриваемый метод нейронных сетей ( $B_{\text{п}}, K_{\text{п}}$ ) –  $K_{\text{п}} = 9.15$ ;
- применение «классических» математических методов сравнения изображений ( $B_{\text{к1}}, K_{\text{к1}}$ ) –  $K_{\text{к1}} = 8.40$ ;
- применение методов, основанных на «классическом» машинном обучении ( $B_{\text{к2}}, K_{\text{к2}}$ ) –  $K_{\text{к2}} = 8.50$ ;
- применение дополнительных оптических систем распознавания ОУМ ( $B_{\text{к3}}, K_{\text{к3}}$ ) –  $K_{\text{к3}} = 7.25$ .

Результаты оценки конкурентоспособности показали, что настоящий научно-исследовательский проект имеет высокую степень конкурентоспособности и ряд преимуществ.

### **3.1.3. SWOT-анализ**

SWOT-анализ – Strengths, Weaknesses, Opportunities, Threats – является комплексным анализом научно-исследовательского проекта и направлен на исследование его внешней и внутренней среды. SWOT-анализ проводится в несколько этапов.

На первом этапе проводится описание сильных и слабых сторон проекта, выявление возможностей и угроз реализации проекта. Полученная для настоящего проекта начальная матрица SWOT-анализа представлена в таблице 5.

Таблица 5 – Начальная матрица SWOT-анализа

	<p>Сильные стороны научно-исследовательского проекта:</p> <p>С1. Высокая точность распознавания значений ОУМ</p> <p>С2. Простота и малая стоимость реализации метода распознавания</p> <p>С3. Малые затраты на перенастройку системы к новым условиям работы</p>	<p>Слабые стороны научно-исследовательского проекта:</p> <p>Сл1. Большое время тренировки нейронных сетей</p> <p>Сл2. Необходимость в создании релевантного тренировочного набора для обучения нейронных сетей</p>
<p>Возможности:</p> <p>В1. Увеличение финансирования области исследований, направленных на создание каналов безопасной связи</p> <p>В2. Распространения каналов передачи информации через значения ОУМ</p>		
<p>Угрозы:</p> <p>У1. Наличие источников сильных турбулентных искажений в местах работы системы</p> <p>У2. Сильные различия условий работы системы в различные периоды</p>		

На втором этапе анализа строятся интерактивные матрицы соответствия сильных и слабых сторон возможностям и угрозам. Полученные для настоящего проекта матрицы соответствия представлены в таблицах 6-9.

Таблица 6 – Матрица смежности сильных сторон и возможностей проекта

Сильные стороны проекта				
Возможности проекта		C1	C2	C3
	B1	+	+	0
	B2	+	+	+

Таблица 7 – Матрица смежности сильных сторон и угроз проекта

Сильные стороны проекта				
Угрозы проекта		C1	C2	C3
	У1	+	0	+
	У2	0	+	+

Таблица 8 – Матрица смежности слабых сторон и возможностей проекта

Слабые стороны проекта			
Возможности проекта		Сл1	Сл2
	B1	+	+
	B2	+	+

Таблица 9 – Матрица смежности слабых сторон и угроз проекта

Слабые стороны проекта			
Угрозы проекта		Сл1	Сл2
	У1	–	0
	У2	–	+

На третьем этапе составляется итоговая матрица. Для построения этой матрицы используются матрицы смежности для слабых и сильных сторон с угрозами и возможностями научного исследования.

Итоговая матрица SWOT-анализа настоящего научно-исследовательского проекта представлена в таблице 10.

Таблица 10 – Итоговая матрица SWOT-анализа

	<p>Сильные стороны научно-исследовательского проекта:</p> <p>С1. Высокая точность распознавания значений ОУМ</p> <p>С2. Простота и малая стоимость реализации метода распознавания</p> <p>С3. Малые затраты на перенастройку системы к новым условиям работы</p>	<p>Слабые стороны научно-исследовательского проекта:</p> <p>Сл1. Большое время тренировки нейронных сетей</p> <p>Сл2. Необходимость в создании релевантного тренировочного набора данных для обучения нейронных сетей</p>
<p>Возможности:</p> <p>В1. Увеличение финансирования области исследований, направленных на создание каналов безопасной связи</p> <p>В2. Распространения каналов передачи информации через значения ОУМ</p>	<p>В1С1С2 – Позволит реализовать проект даже при небольшом дополнительном финансировании</p> <p>В2С1С2С3 – Позволит занять ведущие позиции среди остальных методов распознавания</p>	<p>В1Сл1Сл2 – Увеличение финансирования позволит решить проблемы времени обучения и создания тренировочных наборов данных</p> <p>В2Сл1Сл2 – При широком распространении могут использоваться уже обученные сети и полученные ранее наборы данных и накопленный опыт</p>
<p>Угрозы:</p> <p>У1. Наличие источников сильных турбулентных искажений в местах работы системы</p> <p>У2. Сильные различия условий работы системы в различные периоды</p>	<p>У1С1С3 – Высокая точность метода и возможность его относительно быстрой адаптации позволит обеспечить высокую эффективность</p> <p>У2С2С3 – Малая стоимость и возможности перенастройки системы позволят создать разные варианты системы для работы в разных периодах</p>	<p>У2Сл2 – Невозможность быстрой и недорогой реализации проекта в условиях, при которых необходимо создавать несколько обучающих наборов данных с высокими затратами на каждый из наборов</p>

### 3.1.4. Оценка готовности проекта к коммерциализации

В таблице 11 приведен бланк оценки степени готовности научно-исследовательского проекта к коммерциализации.

Таблица 11 – Бланк оценки готовности научного проекта к коммерциализации

№ п/п	Наименование	Степень проработанности научного проекта	Уровень имеющихся знаний у разработчика
1	Определен научно-технический задел	5	5
2	Определены перспективные направления коммерциализации научно-технического задела	4	4
3	Определены отрасли и технологии для предложения на рынке	4	4
4	Определена товарная форма научно-технического задела для представления на рынок	4	4
5	Определены авторы и осуществлена охрана их прав	4	4
6	Проведена оценка стоимости интеллектуальной собственности	4	4
7	Проведены маркетинговые исследования рынков сбыта	2	2
8	Разработан бизнес-план коммерциализации научной разработки	2	1
9	Определены пути продвижения научной разработки на рынок	2	1
10	Разработана стратегия (форма) реализации научной разработки	3	3
11	Проработаны вопросы международного сотрудничества и выхода на зарубежный рынок	1	1
12	Проработаны вопросы использования услуг инфраструктуры поддержки, получения льгот	3	2
13	Проработаны вопросы финансирования коммерциализации научной разработки	4	3
14	Имеется команда для коммерциализации научной разработки	4	3
15	Проработан механизм реализации научного проекта	4	4
	ИТОГО	50	45

При оценке степени проработанности проекта использовались следующая система баллов: 1 балл означает не проработанность проекта,

2 балла – слабую проработанность, 3 балла – выполнение, но неуверенность в качестве, 4 балл – выполнено качественно, 5 баллов – имеется положительное заключение независимого эксперта. При оценки уровня имеющихся знаний у разработчика система баллов принимала следующий вид: 1 балл означает не знаком или мало знает, 2 – теоретический объем знаний, 3 балла – знание теории и практических примеров применения, 4 – знание теории и самостоятельное выполнение, 5 – знание теории, самостоятельное выполнение и консультации.

Оценка готовности научного проекта к коммерциализации определяется исходя из бланка по формуле:

$$B_{\text{сум}} = \sum_i B_i \quad (3.1.4.1)$$

где  $B_{\text{сум}}$  – суммарное количество баллов по направлению;

$B_i$  – балл  $i$ -го показателя.

Значение  $B_{\text{сум}}$  позволяет оценить меру готовности научной разработки и ее разработчика к коммерциализации. Так, если значение  $B_{\text{сум}}$  лежит в диапазоне от 75 до 60, то такая разработка считается перспективной, знания разработчика достаточными для успешной ее коммерциализации. Если от 59 до 45 – то перспективность выше среднего. Если от 44 до 30 – то перспективность средняя. Если от 29 до 15 – то перспективность ниже среднего. Если 14 и ниже – то перспективность крайне низкая.

Согласно полученным значениям для настоящей научной разработки, она имеет перспективность выше среднего.

### **3.1.5. Методы коммерциализации результатов научно-технического исследования**

Целью коммерциализации настоящего научно-исследовательского проекта является привлечение финансирования для продолжения научно-технических исследований и разработок, обеспечение постоянного притока финансовых средств.

Методом коммерциализации результатов настоящего научно-исследовательского проекта был выбран инжиниринг. Инжиниринг как самостоятельный вид коммерческих операций предполагает предоставление на основе договора инжиниринга одной стороной, именуемой консультантом, другой стороне, именуемой заказчиком, комплекса или отдельных видов инженерно-технических услуг, связанных с проектированием, строительством и вводом объекта в эксплуатацию, с разработкой новых технологических процессов на предприятии заказчика, усовершенствованием имеющихся производственных процессов вплоть до внедрения изделия в производство и даже сбыта продукции.

Выбор данного метода обоснован тем, что система распознавания, рассматриваемая в настоящем научно-исследовательском проекте, необходима для разрабатываемых систем защищенной связи, использующих ОУМ вихревых лазерных пучков. Для проектов таких систем необходимы инженерно-технические услуги, направленные на проектирование и ввод в эксплуатацию систем распознавания, способных к эффективной работе в большом диапазоне сил турбулентных искажений.

### **3.2. Инициация проекта**

В рамках процессов инициации определяются изначальные цели и содержание и фиксируются изначальные финансовые ресурсы. Определяются внутренние и внешние заинтересованные стороны проекта, которые будут взаимодействовать и влиять на общий результат научного проекта

#### **3.2.1. Цели и результат проекта**

Для определения целей и ожидаемых результатов проекта необходимо определить заинтересованные стороны проекта. Под заинтересованными сторонами проекта понимаются лица или организации, которые активно участвуют в проекте или интересы которых могут быть затронуты как положительно, так и отрицательно в ходе исполнения или в результате завершения проекта.

В таблице 12 представлена информация по заинтересованным сторонам научно-исследовательского проекта.

Таблица 12 – Заинтересованные стороны проекта

Заинтересованные стороны проекта	Ожидания заинтересованных сторон
1. Исследователи распространения лазерных пучков, обладающих ОУМ, в турбулентной атмосфере 2. Разработчики систем передачи информации посредством пучков, обладающих ОУМ	1. Получить данные об эффективности и возможности применения нейронных сетей для задачи распознавания ОУМ пучков, распространяющихся в турбулентной атмосфере 2. Иметь точный метод распознавания ОУМ пучков, распространяющихся в турбулентной атмосфере

В таблице 13 представлена информация об иерархии целей проекта и критериях их достижения.

Таблица 13 – Цели и результаты проекта

Цели проекта	Исследование возможности и эффективности применения нейронных сетей для распознавания ОУМ лазерных пучков, распространяющихся в турбулентной атмосфере
Ожидаемые результаты проекта	Разработаны архитектуры нейронных сетей, позволяющих точно распознавать ОУМ пучков в приемлемом диапазоне уровней силы турбулентных искажений
Критерии приемки проекта	Адекватный диапазон силы турбулентных искажений, при которых наблюдается высокая точность распознавания ОУМ
Требования к результату проекта	Требования
	Точность распознавания ОУМ лазерных пучков нейронными сетями выше 0.95.

Определенные в данном разделе заинтересованные стороны и иерархия целей проекта и их достижения позволят более точно сформировать необходимые шаги развития проекта, определить основные и второстепенные задачи и срок их выполнения.

### 3.2.2. Организационная структура проекта

В данном разделе определена рабочая группа проекта, роль каждого участника и выполняемые участниками группы функции. В таблице 14 представлена информация о рабочей группе проекта.

Таблица 14 – Рабочая группа проекта

№ п/п	ФИО, основное место работы, должность	Роль в проекте	Функции	Трудозатраты, час.
1	Богач Е.А., ТПУ, магистрант	Исполнитель по проекту	Разработчик	816
2	Дудоров В.В., ИОА СО РАН, зам. директора по научной работе.	Эксперт проекта	Консультант	312
3	Гергет О.М., ТПУ д.т.н., профессор ОИТ	Руководитель проекта	Координатор	192
ИТОГО				1320

### 3.2.3. Ограничения и допущения проекта

Ограничения проекта – это все факторы, которые могут послужить ограничением степени свободы участников команды проекта, а так же «границы проекта» – параметры проекта или его продукта, которые не будут реализованных в рамках данного проекта. Ограничения настоящего проекта представлены в таблице 15.

Таблица 15 – Ограничения проекта

Фактор	Ограничения / допущения
Источник финансирования	НИ ТПУ
Сроки проекта	14.09.2020 – 30.05.2022
Дата утверждения плана управления проектом	14.09.2020
Дата завершения проекта	30.05.2022
Прочие ограничения и допущения	Отсутствуют

### 3.3. Планирование управления научно-техническим проектом

#### 3.3.1. План проекта

В рамках планирования научного проекта необходимо определить ключевые события проекта, определить их даты и результаты, которые должны быть получены по состоянию на эти даты. Полученные для настоящего научно-исследовательского проекта представлены в таблице 16.

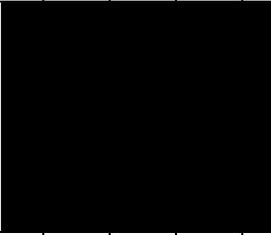
Таблица 16 – Календарный план проекта

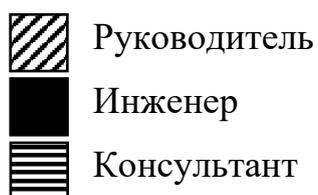
№ п/п	Название	Длительность, дни	Дата начала работ	Дата окончания работ	Состав участников
1	Планирование	7	14.02.22	20.02.22	Гергет О.М. Богач Е.А.
2	Обсуждение структуры работы	3	21.02.22	23.02.22	Гергет О.М. Богач Е.А. Адамов Е.В.
3	Сбор данных и освоение теоретических материалов	17	24.02.22	13.03.22	Богач Е.А. Адамов Е.В.
4	Обучение нейронных сетей	42	14.03.22	24.04.22	Богач Е.А.
5	Анализ и оценка полученных результатов	14	25.04.22	08.05.22	Богач Е.А. Адамов Е.В. Гергет О.М.
6	Тестирование нейронных сетей	5	11.05.22	15.05.22	Богач Е.А. Адамов Е.В.
7	Написание отчета	14	16.05.22	30.05.22	Богач Е.А.
Итого		102	14.02.22	30.05.22	

Диаграмма Ганта – это тип столбчатых диаграмм (гистограмм), который используется для иллюстрации календарного плана проекта, на котором работы по теме представляются протяженными во времени отрезками, характеризующимися датами начала и окончания выполнения данных работ.

В таблицу 17 приведена диаграмма Ганта для настоящего научно-исследовательского проекта.

Таблица 17 – Диаграмма Ганта исследовательского проекта

№ п/п	Вид работ	Исполнители	$T_K$ , кал. дней	Продолжительность выполнения работ												
				февр.		март			апрель			Май				
				2	3	1	2	3	1	2	3	1	2	3		
1	Составление технического задания	Гергет О.М. Богач Е.А.		 												
2	Постановка целей и задач	Гергет О.М. Богач Е.А. Адамов Е.В.		  												
3	Моделирование картин распределения, изучения теории	Богач Е.А.														
4	Формирование архитектур нейронных сетей, обучение сетей	Богач Е.А.														
5	Сравнение нейронных сетей с другими методами, анализ работы	Богач Е.А. Адамов Е.В. Гергет О.М.										  				
6	Проверка эффективности нейронных сетей на новых изображениях	Богач Е.А. Адамов Е.В.											 			
7	Оформление пояснительной записки ВКР	Богач Е.А.														



### 3.4. Бюджет научно-технического исследования

В процессе формирования бюджета текущего научно-исследовательского проекта использована следующая группировка затрат:

- материальные затраты;
- специальное оборудование;
- основная и дополнительная заработная плата;
- отчисления во внебюджетные фонды;
- накладные расходы.

#### 3.4.1. Материальные затраты

Материальные затраты, необходимые для разработки, представлены в таблице 18.

Таблица 18 – Материальные затраты

Наименование	Единицы измерения	Количество	Цена за единицу, руб	Затраты на материалы ( $Z_m$ ), руб
Бумага	пачка	1	1000	1000
Картридж для принтера	шт.	1	1600	1600
Канцелярские принадлежности	набор	1	400	400
Итого				3000

#### 3.4.2. Специальное оборудование

В данную статью включены все затраты, связанные с приобретением специального оборудования, необходимого для проведения работ. В настоящем научно-исследовательском проекте используется свободно распространяемое программное обеспечение (ПО), поэтому дополнительные затраты на ПО не требуются.

Результаты расчета затрат на специальное оборудование представлены в таблице 19.

Таблица 19 – Расчет затрат на специальное оборудование

№ п/п	Наименование оборудования	Кол-во единиц оборудования	Цена единицы оборудования, руб.	Общая стоимость оборудования, руб.
1	Компьютер	1	80000.0	80000,0
2	Программное обеспечение MicrosoftOffice	1	5990.0	5990,0
Итого, руб				85990

### 3.4.3. Основная и дополнительная заработная плата

Статья затрат на основную заработная плата включает основную заработную плату работников, непосредственно занятых выполнением проекта, а также дополнительную заработную плату:

$$Z_{ЗП} = Z_{осн} + Z_{доп}, \quad (3.4.3.1)$$

где  $Z_{ЗП}$  – затраты на заработную плату;

$Z_{осн}$  – затраты на основную заработную плату;

$Z_{доп}$  – затраты на дополнительную заработную плату.

Основная заработная плата рассчитывается по следующей формуле:

$$Z_{осн} = Z_{дн} \cdot T_p, \quad (3.4.3.2)$$

где  $Z_{дн}$  – среднедневная заработная плата работника;

$T_p$  – продолжительность работ, выполняемых работником.

Среднедневная заработная плата рассчитывается по формуле:

$$Z_{дн} = \frac{Z_m \cdot M}{F_d}, \quad (3.4.3.3)$$

где  $Z_m$  – месячный должностной оклад работника;

$M$  – количество месяцев работы без отпуска в течение года;

$F_d$  – действительный годовой фонд рабочего времени работника.

При 5-дневной рабочей неделе и отпуске в 24 рабочих дня  $M = 11.2$  месяца, при отпуске в 48 рабочих дней  $M = 10.4$  месяца.

В таблице 20 приведен баланс рабочего времени.

Таблица 20 – Баланс рабочего времени проекта

Показатели рабочего времени	Руководитель	Исполнитель	Консультант
Календарное число дней	365	365	365
Количество рабочих дней	118	118	118
– выходные дни			
– праздничные дни			
Потери рабочего времени	48	24	48
– отпуск			
Действительный годовой фонд рабочего времени	199	223	199

Месячный должностной оклад работника рассчитывается согласно:

$$Z_m = Z_b \cdot (1 + k_{np} + k_d) \cdot k_p, \quad (3.4.3.4)$$

где  $Z_b$  – базовый оклад;

$k_{np}$  – премиальный коэффициент, который определяется согласно

Положению об оплате труда;

$k_d$  – коэффициент доплат и надбавок составляет примерно 0,2 – 0,5 (в НИИ и на промышленных предприятиях – за расширение сфер обслуживания, за профессиональное мастерство, за вредные условия: определяется Положением об оплате труда)

$k_d$  – районный коэффициент, для г. Томска равный 1.3.

Результаты расчетов затрат на основную заработную плату представлен в таблице 21.

Таблица 21 – Расчет затрат на основную заработную плату

Исполнители	$Z_b$ , руб	$k_p$	$k_{np}$	$k_d$	$Z_m$ , руб	$Z_{он}$ , руб	$T_p$ , дни	$Z_{осн}$ , руб
Научный руководитель	36174.00	1.3	0.3	0.2	70539.3	3686.48	24	88475.52
Инженер	12800	1.3	0.0	0.0	16640.0	835.73	102	85244.46
Консультант	17920	1.3	0.3	0.2	34944.0	1826.22	39	71222.58
Итого								244942.56

Дополнительная заработная плата включает заработную плату за не отработанное рабочее время, но гарантированную действующим законодательством. Расчет дополнительной заработной платы ведется по формуле:

$$Z_{доп} = k_{доп} \cdot Z_{осн}, \quad (3.4.3.5)$$

где  $k_{доп}$  – коэффициент дополнительной заработной платы (на стадии проектирования принимается  $k_{доп} = 0.12$ ).

Результаты расчета представлены в таблице 22.

Таблица 22 – Расчет затрат на дополнительную заработную плату

Исполнители	$Z_{осн}$ , руб	$k_{доп}$	$Z_{доп}$ , руб
Научный руководитель	88475.52	0.12	10617.06
Инженер	85244.46	0.12	10229.34
Консультант	71222.58	0.12	8546.71
Итого			29393.11

Результирующие затраты на заработную плату:

$$Z_{зп} = 244942.56 + 29393.11 = 274335.67 \text{ рублей.}$$

#### 3.4.4. Отчисления во внебюджетные фонды

Отчисления во внебюджетные фонды являются обязательными по установленным законодательством Российской Федерации нормам органам государственного социального страхования (ФСС), пенсионного фонда (ПФ) и медицинского страхования (ФФОМС) от затрат на оплату труда работников.

Величина отчислений во внебюджетные фонды определяется по следующей формуле:

$$C_{внеб} = k_{внеб} \cdot (Z_{осн} + Z_{доп}), \quad (3.4.4.1)$$

где  $C_{внеб}$  – затраты на отчисления во внебюджетные фонды;

$k_{внеб}$  – коэффициент отчислений на уплату во внебюджетные фонды (пенсионный фонд, фонд обязательного медицинского страхования и прочие).

Согласно статье 425 Налогового Кодекса РФ (НК РФ) [38] на 2022 год установлено значение  $k_{внеб} = 30\%$ . Результаты расчета затрат на уплату во внебюджетные фонды представлены в таблице 23.

Таблица 23 – Расчет затрат на уплату во внебюджетные фонды

Исполнитель	$Z_{осн}$ , руб	$Z_{доп}$ , руб
Научный руководитель	88475.52	10617.06
Инженер	85244.46	10229.34
Консультант	71222.58	8546.71
$k_{внеб}$	0.3	
Затраты на уплату во внебюджетные фонды		
Научный руководитель	29727.77 руб	
Инженер	28642.14 руб	
Консультант	23930.79 руб	
Итого	82300.70 руб	

### 3.4.5. Накладные расходы

В статью затрат на накладные расходы включаются затраты на управление и хозяйственное обслуживание. В расчетах эти расходы принимаются в размере 80% от суммы основной и дополнительной заработной платы работников, участвующих в выполнении научно-исследовательского проекта.

Расчет накладных расходов осуществляется по следующей формуле:

$$C_{накл} = k_{накл} \cdot (Z_{осн} + Z_{доп}), \quad (3.4.5.1)$$

где  $C_{накл}$  – затраты на накладные расходы;

$k_{накл}$  – коэффициент затрат на накладные расходы, значение которого принято равным  $k_{накл} = 0.8$ .

Для настоящего проекта накладные расходы составили:

$$C_{накл} = 0.8 \cdot (244942.56 + 29393.11) = 219468.54 \text{ рублей.}$$

### 3.4.6. Формирование бюджета научно-исследовательского проекта

Расчитанная величина затрат научно-исследовательской работы является основой для формирования бюджета затрат проекта, который при формировании договора с заказчиком защищается научной организацией в качестве нижнего предела затрат на разработку научно-технической продукции. Определение бюджета затрат на научно-исследовательский проект приведен в таблице 24.

Таблица 24 –Бюджет затрат научно-исследовательского проекта

Наименование статьи	Сумма, руб
1. Материальные затраты	3000
2. Специальное оборудование	85990
3. Затраты на заработную плату	274335.67
4. Отчисления во внебюджетные фонды	82300.70
5. Накладные расходы	219468.54
6. Бюджет затрат проекта	665094.91

### 3.5. Определение ресурсной (ресурсосберегающей), финансовой, бюджетной, социальной и экономической эффективности

#### 3.5.1. Оценка абсолютной эффективности проекта

В основе проектного подхода к инвестиционной деятельности предприятия лежит принцип денежных потоков. Особенностью является его прогнозный и долгосрочный характер, поэтому в применяемом подходе к анализу учитываются фактор времени и фактор риска. Для оценки общей экономической эффективности используются следующие основные показатели:

- чистая текущая стоимость (NPV);
- индекс доходности (PI);
- внутренняя ставка доходности (IRR);
- срок окупаемости (DPP).

Чистая текущая стоимость (Net Present Value – NPV) – это показатель экономической эффективности инвестиционного проекта, который рассчитывается путём дисконтирования (приведения к текущей стоимости, то есть на момент инвестирования) ожидаемых денежных потоков (как доходов, так и расходов). Расчёт *NPV* осуществляется по следующей формуле:

$$NPV = \sum_{t=1}^n \frac{ЧДП_{опт}}{(1+i)^t} - I_0, \quad (3.5.1.1)$$

где  $ЧДП_{опт}$  – чистые денежные поступления от операционной деятельности;

$I_0$  – разовые инвестиции, осуществляемые в нулевом году;

$t$  – номер шага расчета;

$n$  – горизонт расчета;

$i$  – ставка дисконтирования, представляющая собой желаемый уровень доходности инвестируемых средств.

Расчёт *NPV* позволяет судить о целесообразности инвестирования денежных средств. Если  $NPV > 0$ , то проект оказывается эффективным.

Коэффициент *K* дисконтирования определяется по следующей формуле:

$$K = \frac{1}{(1+i)^t} \quad (3.5.1.2)$$

Расчет чистой текущей стоимости настоящего проекта представлен в таблице 25. При расчете принимались следующие значения: рентабельность проекта – 20 %, амортизационные исчисления – 10 %, бюджет проекта – 579105 рублей. За операционные затраты принята сумма всех затрат с амортизационными исчислениями проекта без учета накладных расходов.

Таблица 25 – Расчет чистой текущей стоимости по проекту в целом

№	Наименование показателей	Шаг расчета				
		0	1	2	3	4
1	Выручка от реализации, руб	0	798114	798114	798114	798114
2	Итого приток, руб	0	798114	798114	798114	798114
3	Инвестиционные издержки, руб	665095	0	0	0	0
4	Операционные затраты, руб	0	426145.87	426145.87	426145.87	426145.87
5	Налогооблагаемая прибыль	0	371968.13	371968.13	371968.13	371968.13
6	Налоги, руб	0	74393.63	74393.63	74393.63	74393.63
7	Итого отток, руб	665095	500539.50	500539.50	500539.50	500539.50
8	Чистая прибыль, руб	0	297574.50	297574.50	297574.50	297574.50
9	Чистый денежный поток (ЧДП), руб	-665095	364084.00	364084.00	364084.00	364084.00
10	Коэффициент дисконтирования при $i = 20\%$	1	0.833	0.694	0.579	0.482
11	Чистый дисконтированный денежный поток (ЧДД), руб	-665095	303403.34	252836.11	210696.76	175580.63
12	Сумма ЧДД, руб	942516.85				
13	Итого NPV, руб	277421.85				

Чистая текущая стоимость по проекту в целом составила 145259 рублей, что позволяет считать проект эффективным.

**Индекс доходности (PI)** – показатель эффективности инвестиции, представляющий собой отношение дисконтированных доходов к размеру инвестиционного капитала. Данный показатель позволяет определить инвестиционную эффективность вложений в данный проект. Значение индекса доходности для эффективного проекта должно быть выше 1.0 и рассчитывается по следующей формуле:

$$PI = \sum_{t=1}^n \frac{ЧДП_{опт}}{(1+i)^t} / I_0 > 1 \quad (3.5.1.3)$$

Индекс доходности настоящего проекта составил:

$$PI = \frac{942516.85}{665095} \approx 1.42 > 1.0 \quad (3.5.1.4)$$

Полученное значение индекса доходности настоящего проекта  $PI \approx 1.42$  также позволяет считать проект эффективным.

**Внутренняя ставка доходности (IRR)** – значение ставки, при которой  $NPV$  обращается в нуль. Формальное определение «внутренней ставки доходности» заключается в том, что это та ставка дисконтирования, при которой суммы дисконтированных притоков денежных средств равны сумме дисконтированных оттоков или равны 0. По разности между  $IRR$  и ставкой дисконтирования  $i$  можно судить о запасе экономической прочности инвестиционного проекта. Чем ближе  $IRR$  к ставке дисконтирования  $i$ , тем больше риск от инвестирования в данный проект.

Между чистой текущей стоимостью ( $NPV$ ) и ставкой дисконтирования ( $i$ ) существует обратная зависимость. Эта зависимость представлена в таблице 26 и на рисунке 3.5.1.

Таблица 26 – Зависимость *NPV* от ставки дисконтирования

№	Показатель	0	1	2	3	4	
1	Чистые денежные потоки, руб	-579105.0	364084.00	364084.00	364084.00	364084.00	<i>NPV</i> , руб
2	Коэффициент дисконтирования						
	0,1	0,909	0,826	0,751	0,683	0,909	
	0,2	0,833	0,694	0,578	0,482	0,833	
	0,3	0,769	0,592	0,455	0,350	0,769	
	0,4	0,714	0,510	0,364	0,260	0,714	
	0,5	0,667	0,444	0,295	0,198	0,667	
	0,6	0,625	0,390	0,244	0,153	0,625	
	0,7	0,588	0,335	0,203	0,112	0,588	
	0,8	0,556	0,309	0,171	0,095	0,556	
	0,9	0,526	0,277	0,146	0,077	0,526	
	1	0,500	0,250	0,125	0,062	0,500	
3	Дисконтированный денежный поток, руб						
	0,1	-665095.0	330985.46	300895.87	273541.70	248674.27	489002.30
	0,2	-665095.0	303403.34	252836.11	210696.76	175580.63	277421.85
	0,3	-665095.0	280064.62	215434.32	165718.71	127475.93	123598.58
	<b>0,4</b>	-665095.0	260060.00	185757.14	132683.67	94774.05	8179.88
	<b>0,5</b>	-665095.0	242722.67	161815.11	107876.74	71917.83	-80762.65
	0,6	-665095.0	227552.50	142220.31	88887.70	55554.81	-150879.68
	0,7	-665095.0	214167.06	125980.62	74106.25	43591.91	-207249.15
	0,8	-665095.0	202268.89	112371.61	62428.67	34682.60	-253343.24
	0,9	-665095.0	191623.16	100854.29	53081.21	27937.48	-291598.86
	1	-665095.0	182042.00	91021.00	45510.50	22755.25	-323766.25

Из таблицы и графика следует, что по мере роста ставки дисконтирования чистая текущая стоимость уменьшается, становясь отрицательной. Значение ставки, при которой *NPV* обращается в нуль, носит название «внутренней ставки

доходности» или «внутренней нормы прибыли». Значение  $IRR$  для настоящего проекта, полученное из графика, составило около 41 %.

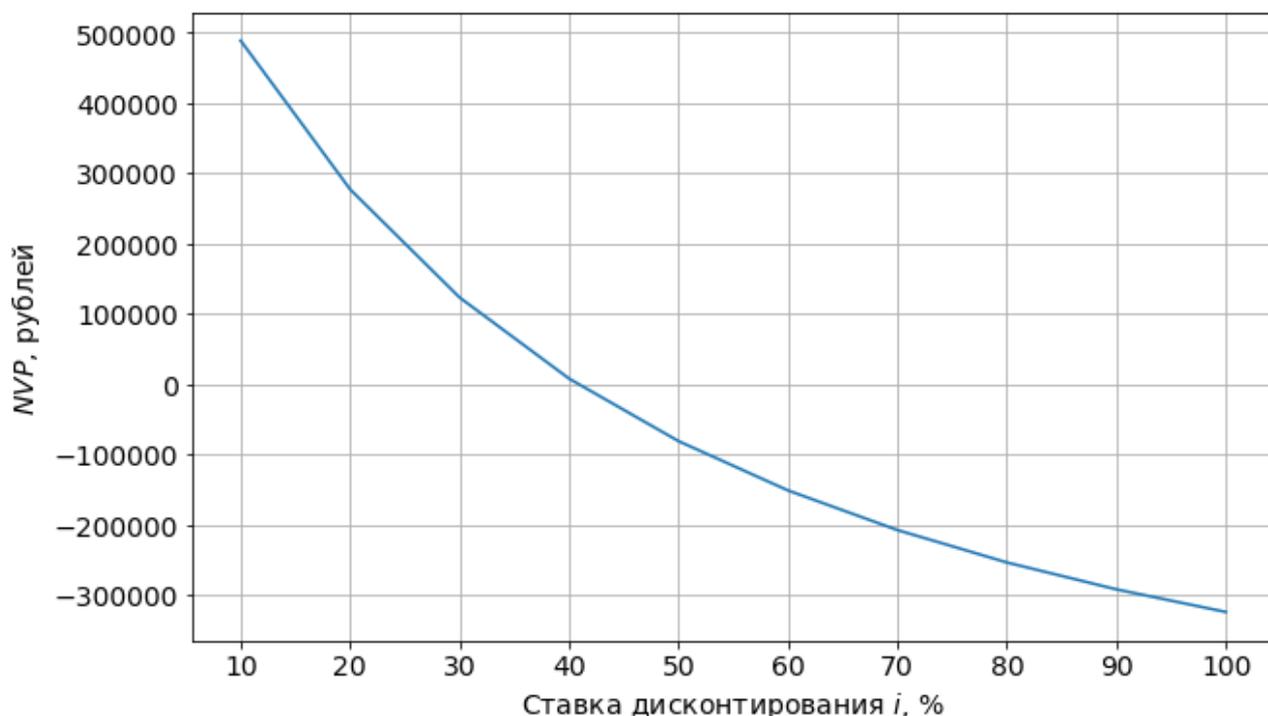


Рисунок 3.5.1 – Зависимость  $NPV$  от ставки дисконтирования

Как отмечалось ранее, одним из недостатков показателя простого срока окупаемости является игнорирование в процессе его расчета разной ценности денег во времени. Этот недостаток устраняется путем определения дисконтированного срока окупаемости. То есть это время, за которое денежные средства должны совершить оборот. Наиболее приемлемым методом установления дисконтированного срока окупаемости  $DDP_{диск}$  является расчет кумулятивного (нарастающим итогом) денежного потока (таблица 27).

Таблица 27 – Расчет дисконтированного срока окупаемости

№	Наименование показателя	0	1	2	3	4
1	Дисконтированный денежный доход ( $i = 20\%$ ), руб	-665095.0	303403.34	252836.11	210696.76	175580.63
2	Кумулятивный денежный поток, руб	-665095.0	-361691.66	-108855.55	101841.21	277421.85
3	Дисконтированный срок окупаемости	$DPP = 1 + 361691.66 / 252836.11 = 1,43$ года				

### 3.5.2. Оценка сравнительной эффективности исследования

Определение эффективности происходит на основе расчета интегрального показателя эффективности научного исследования. Его нахождение связано с определением двух средневзвешенных величин: финансовой эффективности и ресурсоэффективности.

Интегральный показатель финансовой эффективности научного исследования получают в ходе оценки бюджета затрат трех (или более) вариантов исполнения научного исследования. Для этого наибольший интегральный показатель реализации технической задачи принимается за базу расчета (как знаменатель), с которым соотносятся финансовые значения по всем вариантам исполнения.

Интегральный финансовый показатель разработки определяется по следующей формуле:

$$I_{фин}^{исп.i} = \frac{\Phi_{pi}}{\Phi_{max}}, \quad (3.5.2.1)$$

где  $I_{фин}^{исп.i}$  – интегральный финансовый показатель разработки;

$\Phi_{pi}$  – стоимость  $i$ -го варианта исполнения;

$\Phi_{max}$  – максимальная стоимость исполнения научно-исследовательского проекта, в том числе аналогов.

Полученная величина интегрального финансового показателя разработки отражает соответствующее численное увеличение бюджета затрат разработки в разгах (значение больше единицы), либо соответствующее численное удешевление стоимости разработки в разгах (значение меньше единицы, но больше нуля).

Интегральный показатель ресурсоэффективности вариантов исполнения объекта исследования можно определить по следующей формуле:

$$I_{pi} = \sum_i^n a_i \cdot b_i, \quad (3.5.2.2)$$

где  $I_{pi}$  – интегральный показатель ресурсоэффективности для  $i$ -го варианта исполнения разработки;

$a_i$  – весовой коэффициент  $i$ -го варианта исполнения разработки;

$b_i$  – оценка  $i$ -го варианта исполнения разработки, устанавливается экспертным путем по выбранной шкале оценивания.

$n$  – число параметров сравнения.

Расчет интегрального показателя ресурсоэффективности приведен в форме таблицы (таблица 28).

Таблица 28 – Сравнительная оценка характеристик различных вариантов исполнения системы распознавания

Критерии \ ПО	Весовой коэффициент параметра	Текущий проект	Аналог 1	Аналог 2
1. Точность распознавания	0,25	5	5	4
2. Удобство в эксплуатации	0,15	5	5	3
3. Скорость распознавания	0,15	4	4	5
4. Безопасность	0,15	5	5	4
5. Простота эксплуатации	0,10	5	5	4
6. Простота перенастройки системы	0,20	5	1	3
Итого	1	30	26	24

$$I_m^P = 5 \cdot 0.25 + 5 \cdot 0.15 + 4 \cdot 0.15 + 5 \cdot 0.15 + 5 \cdot 0.10 + 5 \cdot 0.20 = 4.85$$

$$I_m^{A1} = 5 \cdot 0.25 + 4 \cdot 0.15 + 5 \cdot 0.15 + 5 \cdot 0.15 + 5 \cdot 0.10 + 1 \cdot 0.20 = 4.05$$

$$I_m^{A2} = 4 \cdot 0.25 + 3 \cdot 0.15 + 5 \cdot 0.15 + 4 \cdot 0.15 + 4 \cdot 0.10 + 3 \cdot 0.20 = 3.80$$

Интегральный показатель эффективности разработки  $I_{инт}^P$  и аналога  $I_{инт}^A$  определяется на основании интегрального показателя ресурсоэффективности и интегрального финансового показателя по формулам:

$$I_{инт}^P = \frac{I_m^P}{I_{фин}^P}; \quad (3.5.2.3)$$

$$I_{инт}^A = \frac{I_m^A}{I_{фин}^A}.$$

Сравнение интегрального показателя эффективности текущего проекта и аналогов позволит определить сравнительную эффективность проекта. Сравнительная эффективность проекта определяется по формуле:

$$\mathcal{E}_{cp} = \frac{I_{инт}^P}{I_{инт}^A}, \quad (3.5.2.4)$$

где  $\mathcal{E}_{cp}$  – сравнительная эффективность проекта.

Сравнение представлено в таблице 29.

Таблица 29 – Сравнительная эффективность разработки

№ п/п	Показатели	Разработка	Аналог 1	Аналог 2
1	Интегральный финансовый показатель разработки	0.2	0.19	1.0
2	Интегральный показатель ресурсоэффективности разработки	4.85	4.05	3.80
3	Интегральный показатель эффективности	24.25	21.32	3.80
4	Сравнительная эффективность вариантов исполнения	6.38	5.61	1,0

### 3.6. Выводы по разделу

В разделе «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение» проведены предпроектный анализ, инициация проекта, планирование проекта и бюджета проекта, оценка абсолютной и сравнительной ресурсной эффективности проекта.

В ходе предпроектного анализа получены следующие результаты:

– Определены потенциальные потребители результатов научно-исследовательского проекта: компании, чьи сферы деятельности затрагивают сферу защищенной передачи данных;

– В результате проведения анализа конкурентных решений результатов проекта определен высокий уровень конкурентоспособности  $K_{II} = 9.15$  в сравнении с конкурентами:  $K_{к1} = 8.40$ ,  $K_{к2} = 8.50$  и  $K_{к3} = 7.25$ ;

– В результате проведения SWOT-анализа определены сильные и слабые стороны, угрозы и возможности проекта:

1. Высокая точность распознавания, простота и малая стоимость реализации, простота его перенастройки позволят занять ведущие позиции на рынке и реализовать проект даже при небольшом финансировании;

2. Высокая точность распознавания и возможности к адаптации позволят решить проблему распознавания в районах сильной турбулентности атмосферы, а простота перенастройки метода позволит создать разные варианты системы для разных условий работы;

3. Увеличение финансирования увеличит скорость обучения нейронных сетей и упростит создание обучающих наборов данных, а широкое распространение систем безопасной лазерной связи позволит использовать уже обученные системы для нескольких районов со схожими условиями;

4. В районах с большими уровнями турбулентности и сложными условиями большие затраты на создание обучающих наборов данных не позволят быстро реализовать проект с малыми затратами.

– Оценка готовности проекта к коммерциализации показала, что перспективность проекта можно выше среднего;

– Для настоящего научно-исследовательского проекта в качестве метода коммерциализации выбран инжиниринг.

В результате инициации проекта определены:

– Заинтересованные стороны проекта: исследователи распространения обладающих ОУМ лазерных пучков в турбулентной атмосфере и разработчики систем передачи информации посредством пучков, обладающих ОУМ;

– Ожидаемые результаты проекта: разработаны архитектуры нейронных сетей, позволяющих точно распознавать ОУМ пучков в приемлемом диапазоне уровней силы турбулентных искажений;

– Рабочая группа проекта: руководитель, инженер и консультант.

При планировании проекта сформирована диаграмма Ганта.

В ходе оценки бюджета определены затраты на проведение проекта:

– Материальные затраты – 3000 рублей;

– Специальное оборудование – 85990 рублей;

– Затраты на заработную плату – 274335.67 рублей;

– Отчисления во внебюджетные фонды – 82300.7 рублей;

– Накладные расходы – 219468.54 рублей.

Бюджет затрат проекта составил 665094.91 рублей.

При оценки ресурсоэффективности получены следующие результаты:

– чистая текущая стоимость проекта  $NPV = 277421.85$  рублей;

– индекс доходности  $PI = 1.42$

– внутренняя ставка доходности  $IRR = 41 \%$ ;

– срок окупаемости проекта составил около 1.43 года.

Полученные показатели позволяют считать проект ресурсоэффективным, имеющим высокий запас прочности и короткий срок окупаемости.

## **4. Социальная ответственность**

В соответствии с ГОСТ Р ИСО 26000-2012 под социальной ответственностью понимается ответственность организации за воздействие ее решений и деятельности на общество и окружающую среду через прозрачное и этическое поведение, которое [39]:

- содействует устойчивому развитию, включая здоровье и благосостояние общества;
- учитывает ожидания заинтересованных сторон;
- соответствует применяемому законодательству и согласуется с международными нормами поведения;
- интегрировано в деятельность всей организации и применяется во всех ее взаимоотношениях.

Объектом исследования данного раздела является работа по исследованию возможности и эффективности применения нейронных сетей для распознавания ОУМ лазерных пучков, распространяющихся через турбулентную атмосферу.

Целью данного раздела является анализ вредных и опасных факторов возникающих при проведении исследования и обоснование мер защиты от них. В разделе также рассматриваются вопросы безопасности в чрезвычайных ситуациях, анализ факторов, влияющих на обеспечение экологической безопасности.

### **4.1. Производственная безопасность**

#### **4.1.1. Отклонение показателей микроклимата в помещении**

Основными показателями, характеризующими микроклимат в производственных помещениях, являются: температура воздуха, относительная влажность воздуха, скорость движения воздуха [40].

Отклонение показателей от оптимальных значений может приводить к возникновению общих и локальных ощущений теплового дискомфорта, напряжению механизмов терморегуляции, ухудшению самочувствия и

понижению работоспособности. Допустимые величины показателей микроклимата производственных помещений при работе на ПЭВМ приведены в таблице 30 [40].

Таблица 30 – Допустимые величины показателей микроклимата

Период года	Температура воздуха, С°		Относительная влажность воздуха, %	Скорость движения воздуха, м/с
	Нижняя допустимая граница	Верхняя допустимая граница		
Холодный	15	24	20-80	<0.5
Теплый	22	28	20-80	<0.5

Общая площадь рабочего помещения составляет 20 м<sup>2</sup>, объем составляет 60 м<sup>3</sup>. По СанПиН 2.2.2/2.4.1340-03 санитарные нормы составляют 6,5 м<sup>2</sup> и 20 м<sup>3</sup> объема на одного человека. Исходя из приведенных выше данных, можно сказать, что количество рабочих мест, равное 1, соответствует размерам помещения по санитарным нормам [41].

После анализа габаритных размеров рассмотрим микроклимат в этой комнате. В качестве параметров микроклимата рассмотрим температуру, влажность воздуха и скорость ветра.

В помещении осуществляется естественная вентиляция посредством наличия легко открываемого оконного проема (форточки), а также дверного проема. По зоне действия такая вентиляция является общеобменной. Основным недостатком - приточный воздух поступает в помещение без предварительной очистки и нагревания. Согласно нормам СанПиН 2.2.2/2.4.1340-03 объем воздуха необходимый на одного человека в помещении без дополнительной вентиляции должен быть более 40м<sup>3</sup> [41]. В нашем случае объем воздуха на одного человека составляет 60 м<sup>3</sup>, из этого следует, что дополнительная вентиляция не требуется. Параметры микроклимата поддерживаются в холодное время года за счет систем водяного отопления с нагревом воды до 100°С, а в теплое время года – за счет

кондиционирования, с параметрами согласно [42]. Нормируемые параметры микроклимата, ионного состава воздуха, содержания вредных веществ должны соответствовать требованиям [43].

#### 4.1.2. Превышение уровней шума

Шум при работе с ПЭВМ может возникнуть как при работе самой ПЭВМ непосредственно, так и ввиду наличия других шумных приборов в помещении с ПЭВМ. Шум с уровнем звукового давления до 35 дБ привычен для человека и не беспокоит его. Повышение этого уровня до 40 дБ создаёт значительную нагрузку на нервную систему, вызывая ухудшения самочувствия, а при длительном действии может быть причиной нервов. Воздействие шума уровнем свыше 80 дБ может привести к потере слуха профессиональной глухости. При действии уровней свыше 140 дБ возможен разрыв барабанных перепонки, контузия, а при уровне более 160 дБ наступает летальный исход. Допустимые значения уровней звукового давления приведены в таблице 31 [44].

Таблица 31 – Допустимые значения уровней звукового давления в октавных полосах частот и уровня звука, создаваемого ПЭВМ

Уровни звукового давления в октавных полосах со среднегеометрическими частотами									Уровни звука в дБА
31.5 Гц	63 Гц	125 Гц	250 Гц	500 Гц	1000 Гц	2000 Гц	4000 Гц	8000 Гц	
86 дБ	71 дБ	61 дБ	54 дБ	49 дБ	45 дБ	42 дБ	40 дБ	38 дБ	50

Основным источником шума в комнате являются компьютерные охлаждающие вентиляторы. Уровень шума варьируется от 35 до 42 дБА. Согласно СанПиН 2.2.2 / 2.4.1340-03, при выполнении основных работ на ПЭВМ уровень шума на рабочем месте не должен превышать 82 дБА. Шумящее оборудование (печатающие устройства, серверы), уровни шума которого превышают нормативные, должно размещаться вне помещений с ПЭВМ. При значениях выше допустимого уровня необходимо предусмотреть средства индивидуальной защиты (СИЗ) и средства коллективной защиты (СКЗ) от шума.

Средства коллективной защиты:

- устранение причин шума или существенное его ослабление в источнике образования;
- изоляция источников шума от окружающей среды (применение глушителей, экранов, звукопоглощающих строительных материалов, например шамотного кирпича);
- применение средств, снижающих шум и вибрацию на пути их распространения;

Средства индивидуальной защиты:

- применение спецодежды и защитных средств органов слуха: наушники, беруши, антифоны.

#### **4.1.3. Повышенный уровень электромагнитных излучений**

Источником электромагнитных излучений в рассматриваемом случае являются дисплеи ПЭВМ. Монитор компьютера включает в себя излучения рентгеновской, ультрафиолетовой и инфракрасной области, а также широкий диапазон электромагнитных волн других частот.

При длительном воздействии ЭМИ повышенного уровня нарушается передача нервных импульсов. В результате появляются вегетативные дисфункции, жалобы на слабость, раздражительность, быструю утомляемость, нарушение сна нарушается высшая нервная деятельность - ослабление памяти, склонность к развитию стрессовых реакций. Нарушения деятельности сердечно-сосудистой системы проявляются, как правило, лабильностью пульса и артериального давления, склонностью к гипотонии, болями в области сердца. В крови отмечается умеренным снижением количества лейкоцитов и эритроцитов. Под действием ЭМИ увеличивается выработка адреналина, активизируется свертываемость крови, снижается активность гипофиза. ЭМИ высокой частоты приводят к нагреву тканей организма. Источниками электромагнитных излучений является ПВЭМ и другое электрооборудование. В таблице 32

представлены допустимые уровни электромагнитных полей, создаваемых ВДУ [41] на расстоянии 50 см.

Таблица 32 – Допустимые уровни ЭМП, создаваемых ВДТ

Наименование параметров		Допустимые значения
Напряженность электрического поля	В диапазоне частот 5 Гц – 2 кГц	25 В/м
	В диапазоне частот 2 кГц – 400 кГц	2.5 В/м
Индукция магнитного поля	В диапазоне частот 5 Гц – 2 кГц	250 нТл
	В диапазоне частот 2 кГц – 400 кГц	25 нТл

Поверхностный электростатический потенциал не должен превышать 500В [41]. В ходе работы использовалась ВДТ со следующими характеристиками: напряженность электромагнитного поля 0,5 В/м; поверхностный потенциал не превышает 450 В. Характеристики используемого ВДТ не превышают установленных допустимых норм.

Предельно допустимые уровни мощности излучения и допустимое рабочее время при этом излучении составляют по ОСТ 54 30013-83:

- до 10 мкВт/см<sup>2</sup> – время работы 8 часов;
- от 10 до 100 мкВт/см<sup>2</sup> – время работы не более 2 часов;
- от 100 до 1000 мкВт/см<sup>2</sup> – время работы не более 20 минут при условии пользования защитными очками;
- для населения в целом мощность излучения не должна превышать 1 мкВт/см<sup>2</sup>.

Для защиты человека от опасного воздействия электромагнитного излучения применяются следующие СКЗ и СИЗ:

СКЗ:

- защита временем – установление рабочего времени, которое не превышает установленные нормы согласно уровню излучений;
- защита расстоянием – проведение работ на максимально возможном удалении от источников ЭМИ;

– снижение интенсивности излучения непосредственно в самом источнике излучения.

– экранирование источника и защита рабочего места от излучения – использование стальных и медных пластин, тонкой фольги и специальных сплавов;

СИЗ:

– Очки и специальная одежда, выполненная из металлизированной ткани (кольчуга). При этом следует отметить, что использование СИЗ возможно при кратковременных работах и является мерой аварийного характера. Ежедневная защита обслуживающего персонала должна обеспечиваться другими средствами.

– Вместо обычных стекол используют стекла, покрытые тонким слоем золота или диоксида олова  $\text{SnO}_2$ .

#### **4.1.4. Поражение электрическим током**

К опасным факторам можно отнести наличие в помещении большого количества аппаратуры, использующей однофазный электрический ток напряжением 220 В и частотой 50 Гц. По опасности электропоражения рабочая комната относится к классу помещений без повышенной опасности, так как отсутствует повышенная влажность, высокая температура, токопроводящая пыль и возможность одновременного соприкосновения токоведущих элементов с заземленными металлическими корпусами оборудования [46 – 49].

Лаборатория относится к помещению без повышенной опасностью поражения электрическим током. Безопасными номиналами являются:  $I < 0.1 \text{ А}$ ;  $U < 36 \text{ В}$ ;  $R_{\text{заземления}} < 4 \text{ Ом}$ . В помещении применяются следующие меры защиты от поражения электрическим током: недоступность токоведущих частей для случайного прикосновения, все токоведущие части изолированы и ограждены. Недоступность токоведущих частей достигается путем их надежной изоляции, применения защитных ограждений (кожухов, крышек, сеток и т.д.),

расположения токоведущих частей на недоступной высоте и в не общедоступных местах и помещениях.

Каждому работнику необходимо знать меры медицинской помощи при поражении электрическим током. В любом рабочем помещении необходимо располагать медицинскую аптечку для оказания первой медицинской помощи.

Поражение электрическим током чаще всего наступает при небрежном обращении с приборами, при неисправности электроустановок или при их повреждении. Для освобождения пострадавшего от токоведущих частей необходимо использовать непроводящие материалы. Если после освобождения пострадавшего из-под напряжения он не дышит, или дыхание слабое, необходимо вызвать бригаду скорой медицинской помощи и оказать пострадавшему доврачебную медицинскую помощь:

- обеспечить доступ свежего воздуха (снять с пострадавшего стесняющую одежду, расстегнуть ворот);
- очистить дыхательные пути;
- приступить к искусственной вентиляции легких;
- в случае необходимости приступить к непрямому массажу сердца.

Любой электроприбор должен быть немедленно обесточен в случаях:

- возникновения угрозы жизни или здоровью человека;
- появления запаха, характерного для горящей изоляции или пластмассы;
- появления дыма или огня;
- появления искрения;
- обнаружения видимого повреждения силовых кабелей или коммутационных устройств.

Для защиты от поражения электрическим током используют СИЗ и СКЗ.

СКЗ:

- Заземление источников электрического тока;

– Использование щитов, барьеров, клеток, ширм, а также заземляющих и шунтирующих штанг, специальных знаков и плакатов.

СИЗ:

Использование диэлектрических перчаток, изолирующих клещей и штанг, слесарных инструментов с изолированными рукоятками, указатели величины напряжения, калоши, боты, подставки и коврики.

#### Расчет освещенности

Местное освещение не должно создавать бликов на поверхности экрана и увеличивать освещенность экрана более 300 лк согласно СанПиН 1.2.3685-21 «Гигиенические нормативы и требования к обеспечению безопасности и (или) безвредности для человека факторов среды обитания» [47].

Расчёт общего равномерного искусственного освещения горизонтальной рабочей поверхности выполняется методом коэффициента светового потока, учитывающим световой поток, отражённый от потолка и стен.

Длина помещения  $a = 5$  м, ширина  $b = 4$  м, высота  $H = 3$  м. Высота рабочей поверхности над полом  $h_p = 0.75$  м. Интегральным критерием оптимальности расположения светильников является величина  $\lambda$ , значение которой для люминесцентных светильников с защитной решёткой лежит в диапазоне 1.1 – 1.3.

Для освещения выбрана лампа дневного света ЛД-40, световой поток которой равен  $\Phi_{\text{ЛД}} = 2300$  лм, выбраны светильники с люминесцентными лампами типа ОДОР-2-40. Такой светильник имеет две лампы мощностью 40 Вт каждая, длина светильника равна  $l_{\text{св}} = 1.227$  м, ширина –  $b_{\text{св}} = 0.265$  м, высота –  $h_{\text{св}} = 0.75$  м. Светильники расположены от потолка на расстоянии  $h_c = 0.3$ . На первом этапе определяется значение индекса освещенности  $i$  по формуле:

$$i = \frac{S}{(a+b) \cdot h}, \quad (4.1.4.1)$$

где  $S$  – площадь помещения;

$h$  – высота подвеса светильника над рабочей поверхностью.

Для рассматриваемого рабочего помещения высота подвеса светильника над рабочей поверхностью составила:

$$h = H - h_{ce} - h_c = 3 - 0.75 - 0.3 = 1.95 \text{ м.}$$

Индекс освещенности рассматриваемого помещения составил:

$$i = \frac{S}{(a+b) \cdot h} = \frac{a \cdot b}{(a+b) \cdot h} = \frac{5 \cdot 4}{(5+4) \cdot 1.95} = 1.14.$$

Необходимое количество ламп для помещения рассчитывается согласно следующей формуле:

$$N_{л} = \frac{E_H \cdot S \cdot K_3 \cdot Z}{\Phi_{л} \cdot \eta} \quad (4.1.4.2)$$

где  $\Phi_{л}$  – необходимый (потребный) световой поток лампы, принимается равным  $\Phi_{л} = \Phi_{лд} = 2300$  лм;

$E_H$  – нормируемая минимальная освещённость, согласно СНиП 23-05-95 в соответствии с разрядом зрительной работы должна быть не ниже 150 лк;

$K_3$  – коэффициент запаса, учитывающий загрязнение светильника (источника света, светотехнической арматуры, стен и прочих, то есть отражающих поверхностей), наличие в атмосфере цеха дыма и пыли, принимается равным 1.5 для данного помещения;

$Z$  – коэффициент неравномерности освещения, отношение  $E_{cp} / E_{min}$  (для люминесцентных ламп принимается равным 1.1);

$\eta$  – коэффициент использования светового потока.

Потолок и стены побелены, значит значение коэффициента отражения принимается равным  $\rho_{п} = 70\%$  и  $\rho_{с} = 50\%$ . Тогда для данного помещения коэффициент использования  $\eta = 0.43$ . Примем также  $E_H = 300$  лк.

Расчетное количество ламп для рабочего помещения составило:

$$N_{л} = \frac{E_H \cdot S \cdot K_3 \cdot Z}{\Phi_{лд} \cdot \eta} = \frac{300 \cdot 20 \cdot 1.5 \cdot 1.1}{2300 \cdot 0.43} \approx 10.01.$$

Так как в светильнике 2 лампы, примем количество ламп  $N_{л} = 12$ . Тогда количество рядов светильников составит  $n_{ряд} = 2$ , а количество светильников в ряду –  $n_{св} = 3$ . Общее количество светильников, необходимых для освещения рабочего помещения составит:

$$N_{св} = n_{ряд} \cdot n_{св} = 2 \cdot 3 = 6.$$

Оптимальное расстояние между светильниками согласно принятому критерию  $\lambda = 1.1$  составило:

$$L = \lambda \cdot h = 1.1 \cdot 1.95 = 2.145 \text{ м.}$$

Чрезмерное увеличение этого параметра приведет к уменьшению освещенности, а чрезмерное уменьшение – к удорожанию затрат на освещение.

Доступное расстояние для размещения светильников составило:

$$a_{\delta} = 5 - 3 \cdot 0.265 = 4.205 \text{ м.}$$

$$b_{\delta} = 4 - 2 \cdot 1.227 = 1.546 \text{ м.}$$

Расстояние между светильниками в ряду  $L_a$  и от светильников до более коротких стен  $L_a / 3$  для данного рабочего помещения определено из уравнения:

$$2 \cdot L_a + 2 \cdot \frac{L_a}{3} = a_{\delta} \text{ м.}$$

$$L_a = \frac{3 \cdot a_{\delta}}{8} = \frac{3 \cdot 4.205}{8} \approx 1.577 \text{ м.}$$

$$\frac{L_a}{3} \approx \frac{1.577}{3} \approx 0.526 \text{ м.}$$

Расстояние между рядами светильников  $L_b$  и от светильников до более коротких стен  $L_b / 3$  для данного рабочего помещения определено из уравнения:

$$L_b + 2 \cdot \frac{L_b}{3} = b_{\delta} \text{ м.}$$

$$L_b = \frac{3 \cdot b_{\delta}}{5} = \frac{3 \cdot 2.546}{5} \approx 0.928 \text{ м.}$$

$$\frac{L_b}{3} \approx \frac{1.528}{3} \approx 0.309 \text{ м.}$$

На рисунке 2.1.4.1 приведена схема размещения светильников.

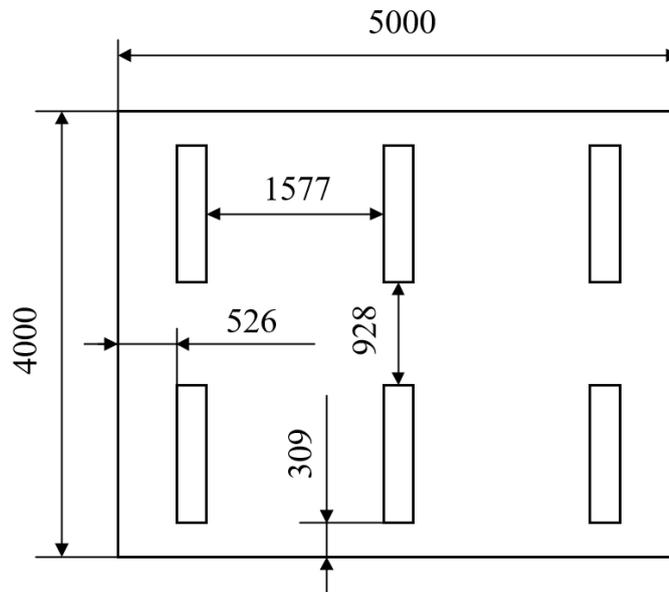


Рисунок 4.1.4.1 – Схема размещения светильников в рабочем помещении

Необходимый световой поток лампы для освещенности помещения определяется по следующей формуле:

$$\Phi_{II} = \frac{E_H \cdot S \cdot K_3 \cdot Z}{N_{\text{л}} \cdot \eta} \quad (4.1.4.3)$$

Для рассматриваемого помещения необходимый световой поток лампы составил:

$$\Phi_{II} = \frac{300 \cdot 20 \cdot 1.5 \cdot 1.1}{12 \cdot 0.43} = 1918.605 \text{ лк.}$$

Для люминесцентных ламп с мощностью 40 Вт и напряжением сети 220В, стандартный световой поток ЛД равен  $\Phi_{\text{ЛД}} = 2300$  Лм.

Световой поток не должен превышать следующий диапазон:

$$-10\% \leq \frac{\Phi_{\text{ЛД}} - \Phi_{II}}{\Phi_{\text{ЛД}}} \cdot 100\% \leq 20\% \quad (4.1.4.4)$$

Для полученных расчетных данных условие принимает следующий вид:

$$-10\% \leq \frac{2300 - 1918.605}{2300} \cdot 100\% \leq 20\%$$

$$-10\% \leq 16.58\% \leq 20\%$$

Как показано выше, световой поток светильников не выходит за пределы установленного диапазона значений.

Мощность осветительной установки составила:

$$P = N_{л} \cdot P_{л} = 12 \cdot 40 = 480 \text{ Вт.}$$

#### **4.1.5. Пожарная опасность**

Согласно НПБ 105-03 лаборатория относится к категории В по взрывопожарной и пожарной опасности.

По степени огнестойкости данное помещение относится к 1-й степени огнестойкости по СНиП 2.01.02-85: выполнено из кирпича, который относится к трудносгораемым материалам.

Возникновение пожара при работе с электронной аппаратурой может быть по причинам как электрического, так и неэлектрического характера. Причиной возникновения пожара неэлектрического характера может являться халатное неосторожное обращение с огнем – курение, оставленные без присмотра нагревательные приборы, использование открытого огня и т.п. Причины возникновения пожара электрического характера: короткое замыкание, перегрузки по току, искрение и электрические дуги и т. п.

Для локализации или ликвидации загорания на начальной стадии используются первичные средства пожаротушения. Первичные средства пожаротушения обычно применяют до прибытия пожарной команды. Огнетушители водо-пенные (ОХВП-10) используют для тушения очагов пожара без наличия электроэнергии. Углекислотные (ОУ-2) и порошковые огнетушители предназначены для тушения электроустановок, находящихся под напряжением до 1000 В. Для тушения токоведущих частей и электроустановок применяется переносной порошковый огнетушитель, например ОП-5. В общественных зданиях и сооружениях на каждом этаже должно размещаться не менее двух переносных огнетушителей. Огнетушители следует располагать на видных местах вблизи от выходов из помещений на высоте не более 1.35 м.

Размещение первичных средств пожаротушения в коридорах, переходах не должно препятствовать безопасной эвакуации людей [50,51].

Для предупреждения пожара и взрыва необходимо предусмотреть:

- специальные изолированные помещения для хранения и разлива легковоспламеняющихся жидкостей (ЛВЖ), оборудованные приточно-вытяжной вентиляцией во взрывобезопасном исполнении - соответствии с ГОСТ 12.4.021-75 и СНиП 2.04.05-86;

- специальные помещения (для хранения в таре пылеобразной канифоли), изолированные от нагревательных приборов и нагретых частей оборудования;

- первичные средства пожаротушения на производственных участках (передвижные углекислые огнетушители ГОСТ 9230-77, пенные огнетушители ТУ 22-4720-80, ящики с песком, войлок, кошма или асбестовое полотно);

- автоматические сигнализаторы (типа СВК-3 М 1) для сигнализации о присутствии в воздухе помещений предвзрывных концентраций горючих паров растворителей и их смесей.

Лаборатория полностью соответствует требованиям пожарной безопасности: наличие охранно-пожарной сигнализации, плана эвакуации, изображенного на рисунке 4.1.5.1, порошковых огнетушителей с поверенным клеймом, табличек с указанием направления к запасному (эвакуационному) выходу.

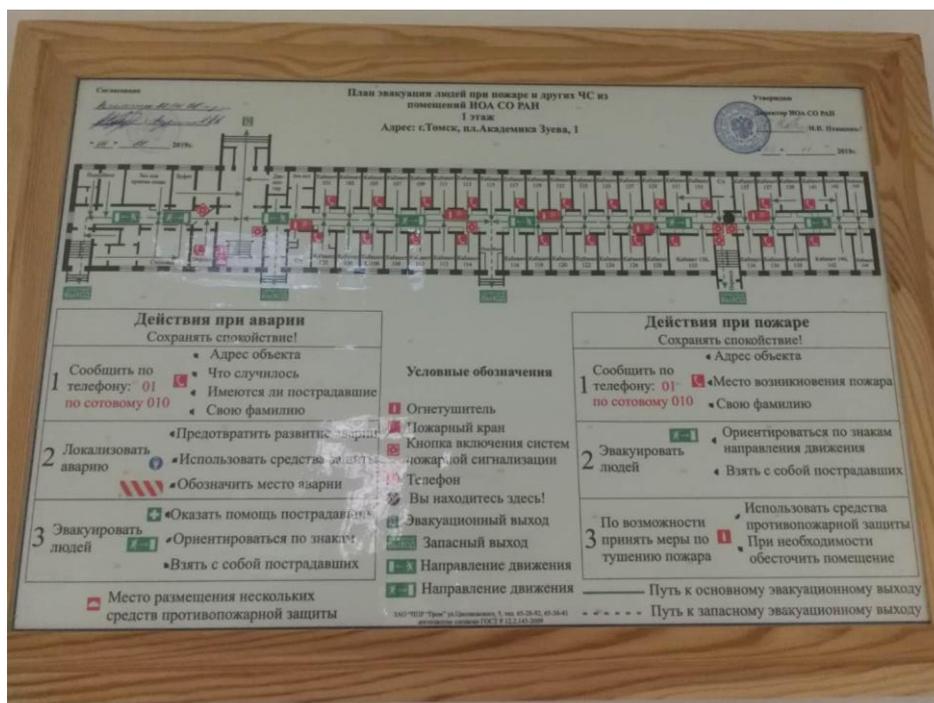


Рисунок 4.1.5.1 – План эвакуации из помещений

## 4.2. Экологическая безопасность

В ПВЭМ присутствуют компоненты, содержащие токсичные вещества и представляющие угрозу как для человека, так и для окружающей среды. К таким веществам относятся: свинец (накапливается в организме, поражая почки, нервную систему), ртуть (поражает мозг и нервную систему), никель и цинк (могут вызывать дерматит); щелочи (прожигают слизистые оболочки и кожу).

Для предотвращения возможного ущерба человеку и окружающей среде необходимо применять комплексные методы утилизации. В этот комплекс мероприятий входят:

- отделение металлических частей от неметаллических;
- переплавка металлических частей для последующего производства;
- специальная переработка неметаллических частей компьютера [44].

Используя правильные подходы к утилизации техники, организация заботится об экологии: количество не перерабатываемых отходов минимизируется, а такие отходы, как пластик, пластмассы, лом черных и цветных металлов, используются во вторичном производстве. Электронные

платы, в которых содержатся драгметаллы, после переработки отправляются на аффинажный завод, после чего чистые металлы сдаются в Гос. фонд [52].

Утилизацию компьютера и оргтехники необходимо проводить следующим образом:

- отделить металлические детали от неметаллов;
- разделить углеродистые металлы от цветмета;
- классифицировать и измельчить неметаллические компоненты техники и распределить в отдельные упаковки
- после накопления на складе транспортировочного количества отправка предприятиям и фирмам, специализирующимся на переработке конкретных видов отходов.

В Томске металлические отходы могут быть отправлены на переработку, например, в компанию «Русметалл», а неметаллические отходы от утилизации оргтехники в компанию «Чистый мир».

Бумажные отходы также загрязняют окружающую среду, и их необходимо комплексно утилизировать. Комплекс мероприятий по утилизации бумажных отходов можно свести к следующим действиям:

- сбор и классификация всех бумажных отходов;
- измельчение (шредирование) и прессовка;
- после накопления транспортировочного количества отправка в перерабатывающие предприятия.

В Томске бумажные отходы могут быть сданы в переработку, например, в компанию «Вторпроект».

### **4.3. Безопасность в чрезвычайных ситуациях**

Природная чрезвычайная ситуация – обстановка на определенной территории или акватории, сложившейся в результате возникновения источника природной чрезвычайной ситуации, который может повлечь или повлек за собой человеческие жертвы, ущерб здоровью людей и (или) окружающей природной

среде, значительные материальные потери и нарушение условий жизнедеятельности людей.

Выполнения проекта производилось в городе Томске с континентально-циклоническим климатом. Землетрясения, наводнения, засухи, ураганы в данном городе отсутствуют. Возможными ЧС на объекте в данном случае, могут быть сильные морозы и диверсия.

Для Сибири в зимнее время года характерны сильные морозы. Достижение критически низких температур приводит к авариям систем теплоснабжения и водоснабжения, сантехнических коммуникаций и электроснабжения, приостановке работы из-за аварий или приостановок движения муниципального транспорта.

Для предотвращения аварий и смягчения их последствий следует при подготовке к зиме:

- газобаллонные калориферы (запасные обогреватели), которые позволят обогреть помещение в случае аварии систем теплоснабжения;
- запасы питьевой и технической воды на складе из расчета не менее 30 л на 1 человека, что позволит обеспечить работу над проектом в случае аварии систем водоснабжения;
- дизельные или бензиновые электрогенераторы и запасы топлива для них, позволяющие обеспечить необходимое для работы над проектом электроснабжение;
- наличие в организации, работающей над проектом, теплого и вместимого транспорта, который обеспечит доставку работников на рабочие места и обратно домой в случае проблем с муниципальным транспортом.

В лаборатории ИОА СО РАН наиболее вероятно возникновение чрезвычайных ситуаций техногенного характера в виде диверсии. Для предупреждения вероятности осуществления диверсии предприятие необходимо оборудовать системой видеонаблюдения, круглосуточной охраной, пропускной системой, надежной системой связи, а также исключения распространения

информации о системе охраны объекта, расположении помещений и оборудования в помещениях, системах охраны, сигнализаторах, их местах установки и количестве. Должностные лица раз в полгода проводят тренировки по отработке действий на случай экстренной эвакуации.

Помещения, в которых проводились работы над проектом, оснащены видеонаблюдением. Вход в ИОА СО РАН охраняется круглосуточно, а также имеется пропускные системы и надежные системы связи. Таким образом, можно считать помещение, в котором проводится работа над проектом, достаточно защищенным от диверсий.

#### **4.4. Перечень научно-технической документации**

1. Классификация. ГОСТ Р ИСО 26000-2012. Руководство по социальной ответственности.

2. СанПиН 2.2.4.548-96 Гигиенические требования к микроклимату производственных помещений.

3. Российская Федерация. Законы. Трудовой кодекс Российской Федерации [текст]: [федер. закон: принят Гос. Думой 21 дек. 2001 г.: по состоянию на 2 фев. 2020 г.]. – М.: Эксмо, 2020. – 224 с.– 5000 экз.

4. СанПиН 2.2.2/2.4.1340-03 Гигиенические требования к персональным электронно-вычислительным машинам и организации работы.

5. ГН 2.2.5.1313-03 Предельно допустимые концентрации (ПДК) вредных веществ в воздухе рабочей зоны

6. СП 51.13330.2011 Защита от шума. Актуализированная редакция СНиП 23-03-2003.

7. ГОСТ 12.0.003-2015 Система стандартов безопасности труда (ССБТ). Опасные и вредные производственные факторы.

8. ГОСТ 12.1.019-2017 ССБТ Система стандартов безопасности труда (ССБТ). Электробезопасность. Общие требования и номенклатура видов защиты.

9. СанПиН 1.2.3685-21 «Гигиенические нормативы и требования к обеспечению безопасности и (или) безвредности для человека факторов среды обитания».

10. ГОСТ Р 12.1.019-2009. Электробезопасность. Общие требования и номенклатура видов защиты.

11. ГОСТ 12.1.030-81. Электробезопасность. Защитное заземление. Зануление.

12. ГОСТ 12.1.004-91. Пожарная безопасность. Общие требования.

13. ГОСТ 12.2.037-78. Техника пожарная. Требования безопасности

14. ГОСТ 30775-2001 Ресурсосбережение. Обращение с отходами. Классификация, идентификация и кодирование отходов.

## Заключение

Результаты работы доказывают эффективность применения нейронных сетей для распознавания распределений интенсивности лазерных пучков, обладающих ОУМ и распространяющихся в турбулентной атмосфере.

В ходе работы рассмотрены по два варианта сверточных и остаточных нейронных сетей, метод корреляции изображений и метод XGBoost с HOG.

На дистанции распространения 1500 м порог распознавания по силе турбулентности для сверточной нейронной сети с полносвязным слоем составил  $C_{nT}^2 \approx 3.5 \cdot 10^{-14} \text{ м}^{-2/3}$ , для остаточной нейронной сети со слоем глобального взятия среднего –  $C_{nT}^2 \approx 3.5 \cdot 10^{-14} \text{ м}^{-2/3}$ , для метода корреляции изображений –  $C_{nT}^2 \approx 1.3 \cdot 10^{-14} \text{ м}^{-2/3}$ , XGBoost с HOG –  $C_{nT}^2 \approx 1 \cdot 10^{-14} \text{ м}^{-2/3}$ . Полученные диапазоны силы турбулентности, в которых как для сверточной, так и для остаточной нейронных сетей точность распознавания превышает 95 %, характеризуют порядка 90% всех атмосферных условий, наблюдаемых в природе. При использовании нейронных сетей получены наивысшие пороги распознавания среди всех рассмотренных методов.

Для дополнительной оценки обобщающей способности рассмотренных методов проведены исследования влияния дистанции распространения на точность распознавания ОУМ пучков, распространяющихся в турбулентной атмосфере при  $C_n^2 \approx 7.2 \cdot 10^{-15} \text{ м}^{-2/3}$ . Диапазон дистанций распространения, при которых точность распознавания превышает 95 %: при использовании сверточных нейронных составил от 1000 м до 3250 м, остаточных нейронных сетей – от 1000 м до 2700 м, для метода корреляции изображений – от 1000 до 2500 м, при использовании метода на основе «XGBoost» и «HOG» не удалось получить точность распознавания выше 95 % на всем диапазоне рассмотренных дистанций распространения.

Для схемы формирования пучков, обладающих ОУМ, массивом волоконных излучателей такие результаты получены впервые.

### Список публикаций студента

1. Богач Е.А., Адамов Е.В., ГЕРГЕТ О.М. РАСПОЗНАВАНИЕ ОРБИТАЛЬНОГО УГЛОВОГО МОМЕНТА СИНТЕЗИРОВАННЫХ МАССИВОМ ВОЛОКОННЫХ ЛАЗЕРОВ ПУЧКОВ ПРИ ИХ РАСПРОСТРАНЕНИИ В ТУРБУЛЕНТНОЙ АТМОСФЕРЕ С ИСПОЛЬЗОВАНИЕ НЕЙРОННЫХ СЕТЕЙ / Е.А. Богач // МОЛОДЕЖЬ И СОВРЕМЕННЫЕ ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ: Сборник трудов XIX Международной научно-практической конференции студентов, аспирантов и молодых ученых. Томск, 2022 / Национальный исследовательский Томский политехнический университет. – Томск: Национальный исследовательский Томский политехнический университет, 2022.

## Список использованной литературы

1. Bernstein, D. J., & Lange, T. (2017). Post-quantum cryptography. In *Nature* (Vol. 549, Issue 7671, pp. 188–194). Nature Publishing Group. <https://doi.org/10.1038/nature23461>
2. Адамов Е. В., Колосов В. В., Левицкий М. Е. Система обработки данных формирования криптографического ключа для беспроводной системы оптической связи // Наука. Технологии. Инновации: сб. науч. тр. / НГТУ. Новосибирск, 2020. Ч. 1. С. 1 – 7.
3. Mavroeidis, V., Vishi, K., Zych, M. D., & Jøsang, A. (2018). The Impact of Quantum Computing on Present Cryptography. In *IJACSA) International Journal of Advanced Computer Science and Applications* (Vol. 9, Issue 3). [www.ijacsa.thesai.org](http://www.ijacsa.thesai.org)
4. Pirandola, S., Andersen, U. L., Banchi, L., Berta, M., Bunandar, D., Colbeck, R., Englund, D., Gehring, T., Lupo, C., Ottaviani, C., Pereira, J. L., Razavi, M., Shamsul Shaari, J., Tomamichel, M., Usenko, V. C., Vallone, G., Villoresi, P., & Wallden, P. (2020). Advances in quantum cryptography. *Advances in Optics and Photonics*, 12(4), 1012. <https://doi.org/10.1364/aop.361502>
5. Adamov, E., Aksenov, V., Dudorov, V., Kolosov, V., & Levitskii, M. (2021). *Vortex beam generation by means of control of the piston shift of a fiber array using a phase forming DOE in active feedback loop*. 55. <https://doi.org/10.1117/12.2613693>
6. Willner, A. E., Huang, H., Yan, Y., Ren, Y., Ahmed, N., Xie, G., Bao, C., Li, L., Cao, Y., Zhao, Z., Wang, J., Lavery, M. P. J., Tur, M., Ramachandran, S., Molisch, A. F., Ashrafi, N., & Ashrafi, S. (2015). Optical communications using orbital angular momentum beams. *Advances in Optics and Photonics*, 7(1), 66. <https://doi.org/10.1364/aop.7.000066>
7. Althobaiti, O. S., & Dohler, M. (2020). Cybersecurity challenges associated with the internet of things in a post-quantum world. *IEEE Access*, 8, 157356–157381. <https://doi.org/10.1109/ACCESS.2020.3019345>

8. Wang, J., Yang, J. Y., Fazal, I. M., Ahmed, N., Yan, Y., Huang, H., Ren, Y., Yue, Y., Dolinar, S., Tur, M., & Willner, A. E. (2012). Terabit free-space data transmission employing orbital angular momentum multiplexing. *Nature Photonics*, 6(7), 488–496. <https://doi.org/10.1038/nphoton.2012.138>
9. Krenn, M., Fickler, R., Fink, M., Handsteiner, J., Malik, M., Scheidl, T., Ursin, R., & Zeilinger, A. (2014). Communication with spatially modulated light through turbulent air across Vienna. *New Journal of Physics*, 16. <https://doi.org/10.1088/1367-2630/16/11/113028>
10. Guo, J., Shi, H., Yang, T., Lv, C., & Qiao, Z. (2022). Atmospheric turbulence compensation for OAM-carrying vortex waves based on convolutional neural network. *Advances in Space Research*, 69(5), 1949–1959. <https://doi.org/10.1016/j.asr.2021.11.039>
11. Jing, G., Chen, L., Wang, P., Xiong, W., Huang, Z., Liu, J., Chen, Y., Li, Y., Fan, D., & Chen, S. (2021). Recognizing fractional orbital angular momentum using feed forward neural network. *Results in Physics*, 28. <https://doi.org/10.1016/j.rinp.2021.104619>
12. Jarrett, W. A., Avramov-Zamurovic, S., Nelson, C., Esposito, J., & Hyde, M. W. (2021). *Neural network classification of structured light in optical turbulence*. 11. <https://doi.org/10.1117/12.2600343>
13. Liu, W., Jin, M., Hao, Y., Deng, D., Wu, R., Wei, Z., & Liu, H. (2021). Efficient identification of orbital angular momentum modes carried by Bessel Gaussian beams in oceanic turbulence channels using convolutional neural network. *Optics Communications*, 498. <https://doi.org/10.1016/j.optcom.2021.127251>
14. Wang, Z., & Guo, Z. (2019). Adaptive Demodulation Technique for Efficiently Detecting Orbital Angular Momentum (OAM) Modes Based on the Improved Convolutional Neural Network. *IEEE Access*, 7, 163633–163643. <https://doi.org/10.1109/ACCESS.2019.2952566>
15. Cao, M., Yin, Y., Zhou, J., Tang, J., Cao, L., Xia, Y., & Yin, J. (2021). Machine learning based accurate recognition of fractional optical vortex modes in

atmospheric environment. *Applied Physics Letters*, 119(14).  
<https://doi.org/10.1063/5.0061365>

16. Aksenov, V. P., Dudorov, V. v., Kolosov, V. v., & Levitsky, M. E. (2020). Synthesized Vortex Beams in the Turbulent Atmosphere. In *Frontiers in Physics* (Vol. 8). Frontiers Media S.A. <https://doi.org/10.3389/fphy.2020.00143>

17. Fleck, J. A., Morris, J. R., & Feit, M. D. (1976). Time-Dependent Propagation of High Energy Laser Beams through the Atmosphere\*. In *Appl. Phys* (Vol. 10).

18. Starikov, F. A., Kochemasov, G. G., Kulikov, S. M., Manachinsky, A. N., Maslov, N. v, Ogorodnikov, A. v, Sukharev, S. A., Aksenov, V. P., Izmailov, I. v, Kanev, F. Y., Atuchin, V. v, & Soldatenkov, I. S. (2007). *Wavefront reconstruction of an optical vortex by a Hartmann-Shack sensor*.

19. Andrews LC Phillips RL. *Laser Beam Propagation through Random Media*. Bellingham: SPIE Optical Engineering Press. (2005). doi: 10.1117/3.626196

20. БАНАХ В. А., СМАЛИХО И. Н. Определение структурной характеристики показателя преломления воздуха из данных, измеряемых когерентным доплеровским лидаром //Оптика атмосферы и океана. – 2014. – Т. 27. – №. 9. – С. 841-845.

21. Vorontsov M.A., Carhart G.W., Cohen M., Cauwenberghs M. “Adaptive optics based on analog parallel stochastic optimization: analysis and experimental demonstration”, *J. Opt. Soc. Am.* 17A (8), 1440-1453 (2000)

22. Николенко С., Кадурын А., Архангельская Е. Глубокое обучение. – "Издательский дом" Питер"", 2017.

23. Rosenblatt, F. (n.d.). THE PERCEPTRON: A PROBABILISTIC MODEL FOR INFORMATION STORAGE AND ORGANIZATION IN THE BRAIN 1. In *Psychological Review* (Vol. 65, Issue 6).

24. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (n.d.). *ImageNet Classification with Deep Convolutional Neural Networks*.  
<http://code.google.com/p/cuda-convnet/>

25. He, K., Zhang, X., Ren, S., & Sun, J. (2015). *Deep Residual Learning for Image Recognition*. <http://arxiv.org/abs/1512.03385>
26. Dalal, N., & Triggs, B. (2005). Histograms of oriented gradients for human detection. *Proceedings - 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR 2005, I*, 886–893. <https://doi.org/10.1109/CVPR.2005.177>
27. Kobayashi, T., Hidaka, A., & Kurita, T. (2008). Selection of histograms of oriented gradients features for pedestrian detection. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 4985 LNCS(PART 2), 598–607. [https://doi.org/10.1007/978-3-540-69162-4\\_62](https://doi.org/10.1007/978-3-540-69162-4_62)
28. Chen, T., & Guestrin, C. (2016). *XGBoost: A Scalable Tree Boosting System*. <https://doi.org/10.1145/2939672.2939785>
29. Friedman, J., Hastie, T., & Tibshirani, R. (2000). ADDITIVE LOGISTIC REGRESSION: A STATISTICAL VIEW OF BOOSTING. In *The Annals of Statistics* (Vol. 28, Issue 2).
30. Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing and Management*, 45(4), 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>
31. Goodfellow I., Bengio Y., Courville A. Deep learning. – MIT press, 2016.
32. Opitz, J., & Burst, S. (2019). *Macro F1 and Macro F1*. <http://arxiv.org/abs/1911.03347>
33. Fisher, R., & Oliver, P. (2013). *Multi-Variate Cross-Correlation and Image Matching*. 62.1-62.10. <https://doi.org/10.5244/c.9.62>
34. Lewis, J. P. (n.d.). *Fast Normalized Cross-Correlation*. Industrial Light & Magic, 1995.
35. Friedman, J. H. (2001). 999 REITZ LECTURE GREEDY FUNCTION APPROXIMATION: A GRADIENT BOOSTING MACHINE 1. In *The Annals of Statistics* (Vol. 29, Issue 5).

36. Татарский В. И. Распространение волн в турбулентной атмосфере / В. И. Татарский. – М. : Наука, 1967.
37. Финансовый менеджмент, ресурсоэффективность и ресурсосбережение: учебно-методическое пособие / Н.А. Гаврикова, Л.Р. Тухватулина, И.Г. Видяев, Г.Н. Серикова, Н.В. Шаповалова; Томский политехнический университет. – Томск: Изд-во Томского политехнического университета, 2014. – 73 с.
38. Налоговый кодекс Российской Федерации (часть первая) от 31.07.1998 № 146-ФЗ (ред. от 27.11.2018) // Собрание законодательства РФ. – № 31. - 03.08.1998. - ст. 3824.
39. ГОСТ Р ИСО 26000-2012. Руководство по социальной ответственности.
40. СанПиН 2.2.4.548-96 Гигиенические требования к микроклимату производственных помещений.
41. СанПиН 2.2.2/2.4.1340-03 Гигиенические требования к персональным электронно-вычислительным машинам и организации работы.
42. Российская Федерация. Законы. Трудовой кодекс Российской Федерации [текст]: [федер. закон: принят Гос. Думой 21 дек. 2001 г.: по состоянию на 2 фев. 2020 г.]. – М.: Эксмо, 2020. – 224 с.– 5000 экз.
43. ГН 2.2.5.1313-03 Предельно допустимые концентрации (ПДК) вредных веществ в воздухе рабочей зоны
44. СП 51.13330.2011 Защита от шума. Актуализированная редакция СНиП 23-03-2003.
45. ГОСТ 12.0.003-2015 Система стандартов безопасности труда (ССБТ). Опасные и вредные производственные факторы.
46. ГОСТ 12.1.019-2017 ССБТ Система стандартов безопасности труда (ССБТ). Электробезопасность. Общие требования и номенклатура видов защиты.

47. СанПиН 1.2.3685-21 «Гигиенические нормативы и требования к обеспечению безопасности и (или) безвредности для человека факторов среды обитания».

48. ГОСТ Р 12.1.019-2009. Электробезопасность. Общие требования и номенклатура видов защиты.

49. ГОСТ 12.1.030-81. Электробезопасность. Защитное заземление. Зануление.

50. ГОСТ 12.1.004-91. Пожарная безопасность. Общие требования.

51. ГОСТ 12.2.037-78. Техника пожарная. Требования безопасности

52. ГОСТ 30775-2001 Ресурсосбережение. Обращение с отходами. Классификация, идентификация и кодирование отходов.

## Приложение А

(справочное)

### Application of neural networks for recognition of intensity distributions of laser beams carrying different values of orbital angular momentum and propagating through a turbulent atmosphere

Студент:

Группа	ФИО	Подпись	Дата
ОВМ02	Богач Егор Андреевич		

Руководитель ВКР

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор ОИТ ИШИТР ТПУ	Гергет Ольга Михайловна	д.т.н.		

Консультант – лингвист отделения иностранных языков ШБИП:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОИЯ ШБИП ТПУ	Панамарёва Анна Николаевна	к.ф.н.		

## Literature review

Nowadays many researches are carrying out investigations to solve the problem of organizing a secure communication in condition of quantum computers. There are several directions of the research which studied solutions of this problem. One of the directions of the research is to increase the resistance of classical cryptographic algorithms to the computing capabilities of quantum computers [6]. Another direction is to explore the possibilities of using physical phenomena to organize secure communication systems. In this direction, studies aimed at using the properties of light to exchange information over free spaces by propagation of vortex beams carrying OAM have been widely developed [7]. In such beams, it is possible to encode information in the spatial phase distribution of lights waves as a result of which certain patterns of the spatial intensity distribution are formed at the radiation receiver for each OAM value: bright central maxima for zero OAM values and ring-like patterns for non-zero OAM values. Light beams with OAM have a helical wave front with an azimuthal phase ranging from 0 to  $2\pi l$ , where  $l$  is the topological charge. There are various methods of the formation of vortex beams carrying OAM.

A successful experiment on the transmission and reception of information encoded in the OAM of a laser beam propagating in the atmosphere over the city of Vienna is presented in [8].

In [9], a successful experiment is presented on the transmission and reception of information encoded in the OAM of a laser beam propagating in the atmosphere over the city of Vienna.

In studies [10–15] using of neural networks to determine the OAM value of laser beams propagating in a turbulent atmosphere is presented.

Based on the analysis of the literature for solving the OAM recognition problem it was decided to investigate the effectiveness of using neural networks.

## A.1. Theoretical part

### A.1.1. Experiment description

We use numerical simulation to form spatial intensity distribution patterns, which are supposed to be obtained during propagation of laser beams in turbulent atmosphere. We use the model from [5] with considering atmospheric turbulence to form intensity patterns.

In this work carrying OAM beams are forming by the method of controlling the spatial characteristics of azimuthally polarized beams synthesized as a result of coherent combining of Gaussian beams emitted by a spatially ordered array of fiber lasers. Figure A.1.1.1 describes the scheme of this method. Two modifications of the scheme are considered.

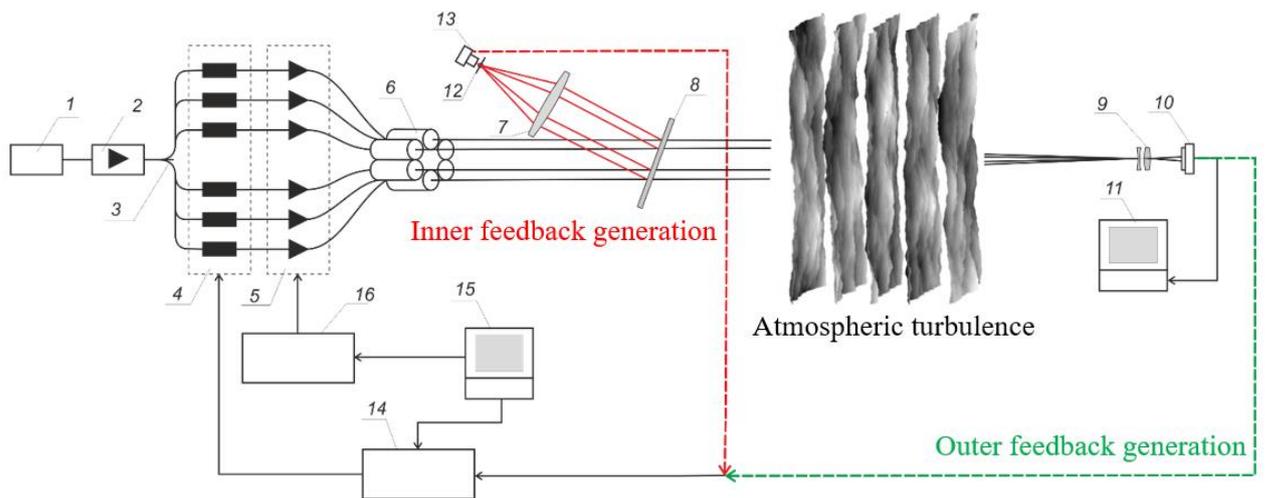


Figure A.1.1.1 – Scheme of experiment: 1 – narrowband laser, 2 – optical fiber amplifier, 3 – 1×8 fiber splitter, 4 – phase modulators, 5 – power amplifiers, 6 – fiber collimators, 7 – long-focus lens, 8 – beam splitter, 9 – collimator, 10 – CCD-matrix, 11 – computer, 12 – pinhole, 13 – broadband photodetector, 14 – multichannel optimizing SPGD processor, 15 – control computer, 16 – power amplifier controller.

Figure A.1.1.2 illustrates intensity patterns, which are obtained when laser beams propagate in atmosphere without phase distortions.

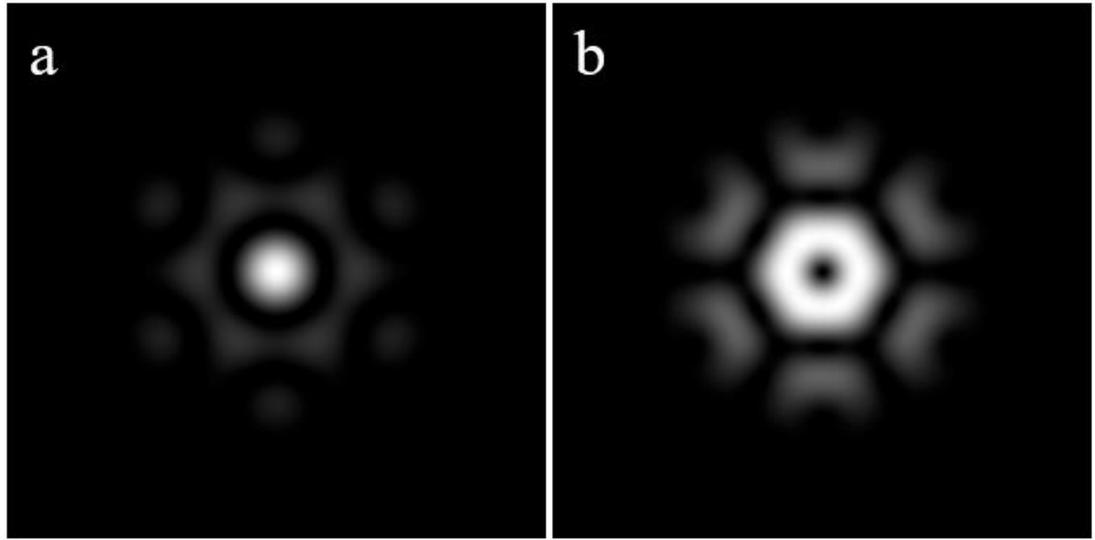


Figure A.1.1.2 – Spatial intensity distribution patterns, obtained in atmosphere without phase distortions: a – with 0 value of OAM, b – with 1 value of OAM.

It can be seen from the figure above, that spatial intensity distribution patterns are carrying information about OAM value.

The parabolic equation for a scalar field E [16], the method of phase screens [16, 17] and Andrews spectrum [18,19] were used in numerical scheme to simulate propagation of laser beams in turbulent atmosphere.

We use the atmospheric turbulence structure parameter  $C_n^2$  [20] to characterize the turbulence intensity. Depended on the value of  $C_n^2$  three levels of atmospheric turbulence intensity are conventionally considered [14]:

- weak atmospheric turbulence strength –  $C_n^2 < 1 \cdot 10^{-15} \text{ m}^{-2/3}$ ;
- medium atmospheric turbulence strength –  $1 \cdot 10^{-15} < C_n^2 < 1 \cdot 10^{-14} \text{ m}^{-2/3}$ ;
- strong atmospheric turbulence s strength –  $C_n^2 > 1 \cdot 10^{-14} \text{ m}^{-2/3}$ .

Atmospheric turbulence obtained by the phase screens method leads to the destruction of the spatial intensity distribution patterns that carry information about the OAM value. Figure A.1.1.3 illustrates destructions of intensity patterns.

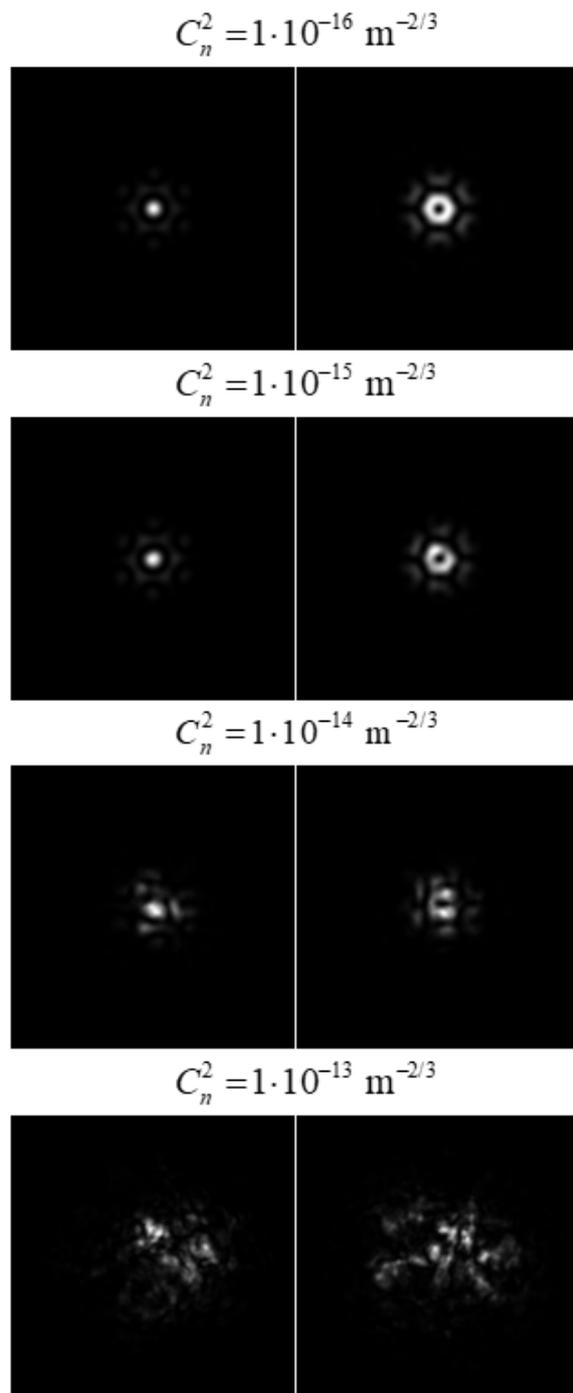


Figure A.1.1.3 – Spatial intensity distribution patterns obtained by laser beam propagation in different atmospheric turbulence strength for OAM = 0 left and OAM = 1 right

In this work we use both modification of the scheme for numeric simulation the intensity patterns produced by laser beams carrying two different values of OAM: 0 and 1. A modification of the scheme with the internal feedback signal registration is used to model intensity patterns obtained by laser beams propagation over the distance

of 1500 m with  $C_n^2 \in [1 \cdot 10^{-16}; 5 \cdot 10^{-14}] \text{ m}^{-2/3}$ . This spatial intensity distribution patterns was used to train models and analyze its performance. A modification of the scheme with external feedback registration was used to simulate intensity distribution patterns obtained by laser beams propagation over the distances 1000 – 5000 m with  $C_n^2 = 7.2 \cdot 10^{-15} \text{ m}^{-2/3}$  and  $C_n^2 = 3 \cdot 10^{-14} \text{ m}^{-2/3}$ . This spatial intensity distribution patterns was used for analyze models performance depended on different distances of propagation of laser beams.

### **A.1.2. Neural network, training of neural networks**

The idea of creating artificial neural networks is based on the structure and operation of neurons in the human brain [22]. The first model of a neural network is Rosenblatt's linear perceptron, which he described in the 1950s [23]. Rosenblatt's perceptron can be considered as a linear classification model [22]. The input of the perceptron is a one-dimensional array  $x$  of length  $N$ . The input array is multiplied by the array of weights  $w$ , and then the results of the multiplication are summed and fed as an argument to the activation function  $f$ . The result of the model operation is formed according to the expression (A.1.2.1):

$$y = f \left( \sum_{i=0}^N w_i x_i \right) \quad (\text{A.1.2.1})$$

Perceptrons are the elementary units from which multilayer neural networks are built. Each layer of such a neural network usually consists of several neurons. Figure A.1.2.1 shows a scheme of organization of a feed-forward neural network. Feed-forward networks consist of three types of layers: input layers, hidden layers, and output layers. Only one-dimensional arrays are used as input data in such networks.

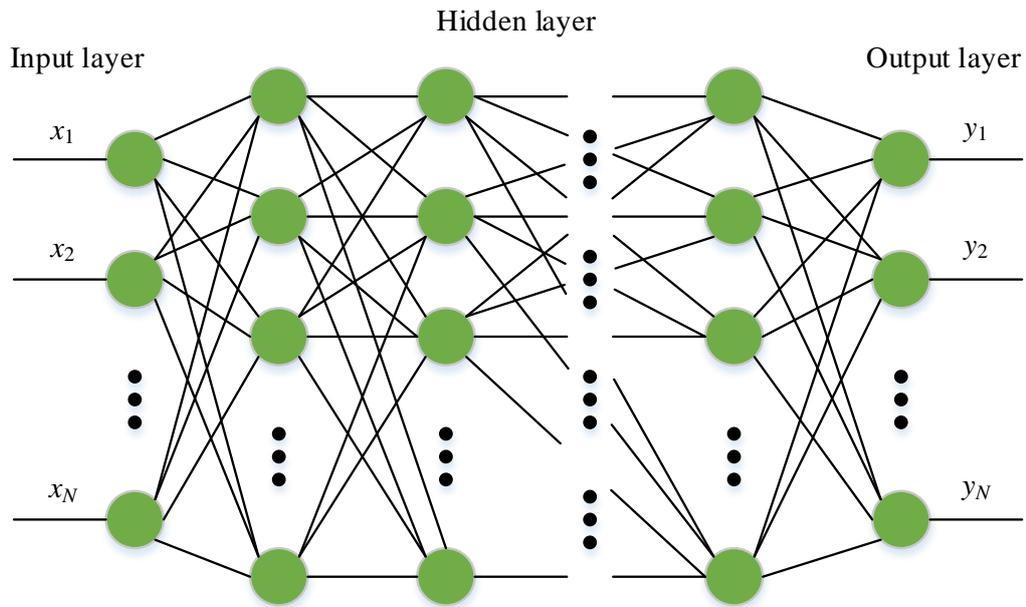


Figure A.1.2.1 – Structure of feed-forward neural network

The input layer receives the original data. The number of neurons in the input layer corresponds to the size of the input data array. Only one value from the input data array is fed to the input of each neuron of the input layer. The output value of each neuron in the input layer is connected to all neurons in the hidden layer following the input layer through weight coefficients  $w$  [22].

Feed-forward neural network can contain several number of hidden layers. The number of neurons in these layers, as well as the number of layers, is determined when creating a neural network and is limited by computational capabilities. All output values of neurons from the previous layer are fed to the input of each neuron of the hidden layer. All output values of the neurons of the hidden layer are fed to the input of each neuron of the next layer. That is, each neuron of the hidden layer is connected at the input with all the neurons of the previous layer, and at the output with all the neurons of the next layer. Neurons of hidden layer are also connected with others through weight coefficients. The hidden layer's input weights are the output weights of the previous layer, and the hidden layer's output weights are the input weights to the next layer [22].

The output layer makes the «solution» of the neural network based on the input data. The number of neurons in this layer depends on the problem being solved: in the

regression problem only one neuron is used in the output layer and in the classification problem the number of neurons corresponds to the number of classes to be determined.

Each  $j$ -th neuron of any layer (except for the input one) of the feed-forward neural network is connected to the neurons of the previous layer according to expression (A.1.2.2).

$$y_j = f \left( \sum_{i=0}^N w_{ji} x_i \right), \quad (\text{A.1.2.2})$$

where  $y_j$  – output of  $j$ -th neuron of considered layer;

$f$  – activation function of  $j$ -th neuron of considered layer;

$w_{ji}$  – connection weight for  $j$ -th neuron of considered layer and  $i$ -th neuron of previous layer;

$x_i$  – output of  $i$ -th neuron of previous layer;

$N$  – number of neurons in previous layer.

In supervised deep learning there are concepts of forward and back propagation [22]. With forward propagation, labeled data is fed to the input of the neural network and passes through all layers leads to forming output values at the output layer. Next, the output values obtained after forward propagation are compared with the real value of the predicted function in the regression problem or with the real class label in the classification problem. Value of the loss function denoted as  $L$  is calculated as a result of comparison. This value is then back propagate through layers, updating the weights and training the neural network. Commonly used loss function are standard deviation in regression problem and cross entropy in classification problem. Weight coefficients are updated in a way to minimize the loss function at each training step, so the optimization problem is solved. Today there are several algorithms to solve such optimization problem: gradient descent, adagrad, adam, adamax etc.

At optimization step  $t$ , the values of the weight coefficients of the  $j$ -th neuron in the  $l$  layer are updated according to the expression:

$$w_t^{l,j} = w_{t-1}^{l,j} + \Delta w_t^{l,j}, \quad (\text{A.1.2.3})$$

where  $w_t^{l,j}$  – vector of weights of  $j$ -th neuron of  $l$ -th layer at step  $t$ ;

$w_{t-1}^{l,j}$  – vector of weights of  $j$ -th neuron of  $l$ -th layer at step  $t - 1$ ;

$\Delta w_t^{l,j}$  – vector of weights update of  $j$ -th neuron of  $l$ -th layer at step  $t$ .

The weights update vector in classical gradient descent is determined according to the expression:

$$\Delta w_t^{l,j} = -\eta \nabla L(w_t^{l,j}), \quad (\text{A.1.2.4})$$

where  $\eta$  – learning rate;

$\nabla L(w)$  – gradient of loss function by weights  $w$ .

Calculation of gradients in neural networks is carried out according to the chain rule. Gradient by weights is calculated according to expression:

$$\frac{\partial L}{\partial w_j^l} = \sum_i \frac{\partial L}{\partial y_i^{l+1}} \frac{\partial y_i^{l+1}}{\partial f_i^{l+1}} \frac{\partial f_i^{l+1}}{\partial w_{ji}^{l+1}} x_i^{l+1}, \quad (\text{A.1.2.5})$$

Back propagation of loss to the previous layer is determined by expression:

$$\frac{\partial L}{\partial x_j^l} = \sum_i \frac{\partial L}{\partial y_i^{l+1}} \frac{\partial y_i^{l+1}}{\partial f_i^{l+1}} \frac{\partial f_i^{l+1}}{\partial x_i^{l+1}} w_{ji}^{l+1}, \quad (\text{A.1.2.6})$$

### A.1.3. Convolution neural network, image classification

Feed-forward neural networks can work only with one-dimensional data examples. In image classification problem not only intensity of pixel is important but both pixel intensity and coordinates. Consequently, feed-forward neural network cannot work properly with image classification problem without special preprocessing. Convolution neural networks was proposed as a solution of this problem. Convolution neural networks allow considering both pixels intensity and spatial distribution and providing state-of-the-art results in many image related problems, for example in ImageNet competition [24]. Convolution neural networks consist of special layers, which allow extracting feature from spatial and intensity pixel distribution.

Convolution is the operation after which convolution neural networks got their name. Convolution is determined by following expression:

$$y_{i,j}^l = \sum_{a,b=-d}^d w_{a,b} x_{i+a,j+a}^l, \quad (\text{A.1.3.1})$$

where  $y_{i,j}^l$  – convolution result;

$w_{a,b}$  – filter's weights matrix with size  $2d + 1 \times 2d + 1$ ;

$x_{i+a,j+a}^l$  – previous layer output.

In convolution of image with filter with size  $2d + 1 \times 2d + 1$  to traverse the entire image only  $(2d + 1)^2$  weights are used. Output of convolution is a matrix with size  $M \times N$  or  $M - d + 1 \times N - d + 1$  depended on the way of processing of borders pixels [22]. Convolution layers usually consist of several different filters.

Convolution neural networks have another important advantage in addition to considering spatial pixels distribution: convolution allows obtaining a large number of features using a little numbers of weights because weights reusing. For examples let's consider convolution of a single channel image with size  $28 \times 28$  with  $3 \times 3$  filter. We can place entire  $3 \times 3$  filter in  $28 \times 28$  image  $26 \cdot 26 = 676$  times, i.e. we get 676 features using only 10 weights. In comparison, using feed-forward neural network requires  $28 \cdot 28 \cdot 676 = 529984$  weights to achieve 676 features.

Activation operation usually follows convolution operation. This operation takes an activation function from each convolution output value. Description of activation operation is presented in following expression:

$$z_{i,j}^l = f(y_{i,j}^l), \quad (\text{A.1.3.2})$$

where  $f$  – neuron activation function;

$z_{i,j}^l$  – result of activation operation.

Output matrix mentioned above layers is conventionally named 'feature map'.

The pooling layers can follow an activation layer in convolutional neural networks. This layers provide down a sampling feature map for decreasing size of a processed feature maps. Usually, polling layers counting mean values (mean-pooling) or maximum values (max-pooling) in the sliding window. Expression (A.1.3.3) presents max-pooling with  $2d + 1 \times 2d + 1$  size of the sliding window.

$$x_{i,j}^{l+1} = \max_{-d \leq a \leq d, -d \leq b \leq d} z_{i+a, j+b}^l, \quad (\text{A.1.3.3})$$

where  $x_{i,j}^{l+1}$  – pooling output.

Combination of convolution, activation and pooling layers can follow each other several times. After these combinations several dense layers usually are used before output layer. Figure A.1.3.1 shows an example of the architecture of convolution neural network for image classification problem.

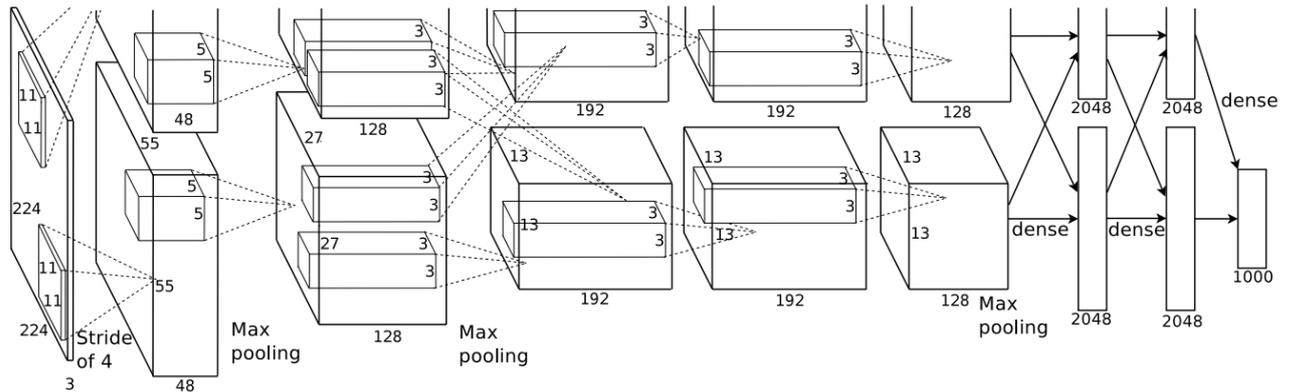


Figure A.1.3.1 – Example of the architecture of convolution neural network for image classification problem [24]

Big number of layers and weights in deep neural networks can lead to vanishing or exploding gradients and degradation problem. In [25] residual neural networks a solution of this problems was proposed. Figure A.1.3.2 describes the residual block, which used in residual learning.

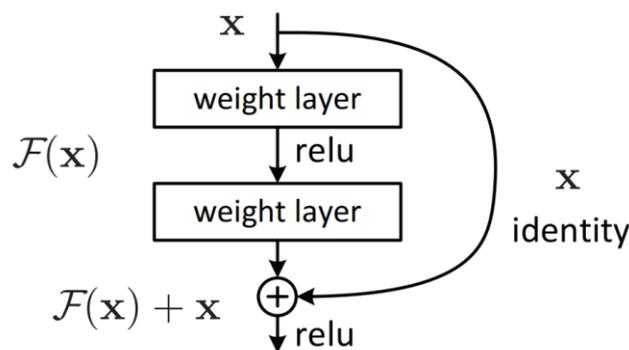


Figure A.1.3.2 – Residual block

The idea of residual learning is the transfer of information skipping the computational layers. Mathematically this is represented as the sum of the outputs of the current computational layer and its inputs or the inputs of the residual block.

#### A.1.4. Histogram of oriented gradients

Histogram of oriented gradients (HOG) is a method of extracting features from an image based on calculating the magnitudes and directions of gradients. The result of applying HOG to an image is a histogram of gradient amplitudes in directions [26].

For computing HOG image splits up by local regions. In this local region then local gradients  $dx$  and  $dy$  are computed in all points. Gradient are computed by Sobel filter [27]. Magnitudes of gradients  $m(x, y)$  and gradients directions  $\theta(x, y)$  are computed using local gradients by following expressions:

$$m(x, y) = \sqrt{dx(x, y)^2 + dy(x, y)^2} \quad (\text{A.1.4.1})$$

and

$$\theta(x, y) = \begin{cases} \arctg\left(\frac{dy(x, y)}{dx(x, y)}\right) - \pi, & \text{if } dx < 0, dy < 0 \\ \arctg\left(\frac{dy(x, y)}{dx(x, y)}\right) + \pi, & \text{if } dx < 0, dy > 0. \\ \arctg\left(\frac{dy(x, y)}{dx(x, y)}\right), & \text{otherwise} \end{cases} \quad (\text{A.1.4.2})$$

Each local region is divided into cells. In each cell, a histogram of the total amplitudes for usually 9 directions is calculated. The direction angles in case of 9 directions represent angular intervals having a width of  $360^\circ / 9 = 40^\circ$ . The vector corresponding to this histogram represents the extracted features – HOG.

When dividing the original image into  $R$  local regions, each of which is divided into  $C$  cells, a vector of length  $R \cdot C \cdot 9$  will be obtained as the result of calculating HOG for considered image. This vector describes the local shape of objects and carries this information about each calculated cell.

### A.1.5. Tree gradient boosting method XGBoost

Tree boosting is an efficient machine learning method that is now widely used. XGBoost is a scalable end-to-end tree boosting system that is widely used in many machine learning problems to achieve state-of-the-art results. XGBoost uses fewer resources in comparison with other existing systems to scale beyond even billions of examples.

For dataset consisting of  $n$  instances with  $m$  features tree ensemble method uses  $K$  additive functions to predict the output values [28]:

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) \quad (\text{A.1.5.1})$$

where  $\hat{y}_i$  – predicted by model target value for  $i$ -th instance from dataset;

$x_i$  –  $i$ -th instance from dataset.

The following function is minimized during learning the set of function, used by the tree boosting model:

$$L = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k) \quad (\text{A.1.5.2})$$

where  $l(\hat{y}_i, y_i)$  – convex differentiable loss function, which is used to measure the difference between true value  $y_i$  and predicted value  $\hat{y}_i$ .

The second part in expression (A.1.5.2) is responsible for regularization, penalizing the model for its complexity. Regularization allows smoothing the model's weights and avoiding over-fitting of the model during training. This parameter is determined by the following formula [28]:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \|\omega\|^2 \quad (\text{A.1.5.3})$$

где  $\gamma, \lambda$  – regularization parameters;

$T$  – number of tree leaves;

$\omega$  – model's weights vector.

Models in tree boosting method are trained in additive manner. Let  $\hat{y}_i^{(t)}$  be the prediction for the  $i$ -th instance of the dataset at the  $t$ -th iteration. It is also necessary to greedily add  $f_t$  to minimize the following function:

$$L^{(t)} = l\left(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)\right) + \Omega(f_t) \quad (\text{A.1.5.4})$$

Second-order approximation is used to optimize the objective function quickly in general setting [29]:

$$\tilde{L}^{(t)} = \left[ l\left(y_i, \hat{y}_i^{(t-1)}\right) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t) \quad (\text{A.1.5.5})$$

where  $g_i = \frac{\partial l\left(y_i, \hat{y}_i^{(t-1)}\right)}{\partial \hat{y}_i^{(t-1)}}$ ;

$$h_i = \frac{\partial^2 l\left(y_i, \hat{y}_i^{(t-1)}\right)}{\left(\partial \hat{y}_i^{(t-1)}\right)^2}.$$

After removing constant terms following the objective function at the step  $t$  we obtain:

$$\tilde{L}^{(t)} = \left[ g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t) \quad (\text{A.1.5.6})$$

Let  $I_j$  be the set of the instances of leaf  $j$ . Expression (A.1.5.5) can be rewritten by expanding  $\Omega(f_t)$  as follows:

$$\begin{aligned} \tilde{L}^{(t)} &= \sum_{i=1}^n \left[ g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 = \\ &= \sum_{j=1}^T \left[ \left( \sum_{i \in I_j} g_i \right) \omega_j + \frac{1}{2} \left( \sum_{i \in I_j} h_i + \lambda \right) \omega_j^2 \right] + \gamma T \end{aligned} \quad (\text{A.1.5.7})$$

For a fixed considered  $q(x)$  the optimal weight  $\omega_j^*$  of leaf  $j$  can be computed by the following expression:

$$\omega_j^* = - \frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda}. \quad (\text{A.1.5.8})$$

Corresponding value of loss function is computed by the following expression:

$$L^{(t)}(q) = -\frac{1}{2} \sum_{j=1}^T \frac{\left(\sum_{i \in I_j} g_i\right)^2}{\sum_{i \in I_j} h_i + \lambda} + \gamma T, \quad (\text{A.1.5.9})$$

Usually, it is impossible to enumerate all the possible tree structures  $q$ . A greedy algorithm that starts from a single leaf and iteratively adds branches to the tree is used instead.

Let  $I_L$  be the set of instances of the left node of the leaf  $j$  and  $I_R$  be the set of instances of the right node of the leaf  $j$ . Let also  $I = I_L \cup I_R$ . After this the loss reduction after the split is given by:

$$L_{split} = -\frac{1}{2} \left[ \frac{\left(\sum_{i \in I_L} g_i\right)^2}{\sum_{i \in I_L} h_i + \lambda} + \frac{\left(\sum_{i \in I_R} g_i\right)^2}{\sum_{i \in I_R} h_i + \lambda} - \frac{\left(\sum_{i \in I} g_i\right)^2}{\sum_{i \in I} h_i + \lambda} \right] - \gamma T. \quad (\text{A.1.5.10})$$

This formula is usually used in practice for evaluating the split candidates.

#### A.1.6. Performance metrics

The correctness of the classification model can be assessed by counting the number of correctly recognized examples of a class (TP), the number of examples incorrectly recognized as belonging to the class (FP), the number of examples of a class not recognized as belonging to the class (FN), the number of examples correctly recognized as not belonging to the class (TN) [30]. These characteristics form confusion matrix. Table A.1 illustrates an example of such confusion matrix for a binary classification problem.

Table A.1 – Confusion matrix

	classified as positive	classified as negative
positive	TP	FP
negative	FN	TN

In machine learning following metrics conventionally accepted to be used for evaluating the performance of classification models: *accuracy*, *precision*, *recall* and *F1-score* [31].

The *accuracy* metric shows the proportion of correctly predicted classes out of the total number of marked examples. To calculate *accuracy* in the binary classification problem, the following formula is used [31]:

$$accuracy = \frac{TP + TN}{TP + FN + TN + FP}. \quad (\text{A.1.6.1})$$

In the classification problem with  $K \geq 3$  classes, to find the *accuracy* metric of the model for the  $i$ -th class, the following formula is used:

$$accuracy_i = \frac{TP_i + TN_i}{TP_i + FN_i + TN_i + FP_i}, \quad (\text{A.1.6.2})$$

and following formula is used to find the average *accuracy* metric of the model for all classes:

$$accuracy_M = \frac{\sum_{i=1}^K \frac{TP_i + TN_i}{TP_i + FN_i + TN_i + FP_i}}{K}. \quad (\text{A.1.6.3})$$

The *precision* metric shows the proportion of correctly defined instances of a class among all instances defined as belonging to that class. In a binary classification problem, *precision* is calculated using the following formula [31]:

$$precision = \frac{TP}{TP + FP}. \quad (\text{A.1.6.4})$$

In the classification problem with  $K \geq 3$  classes, to find the *precision* metric of the model for the  $i$ -th class, the following formula is used:

$$precision_i = \frac{TP_i}{TP_i + FP_i}, \quad (\text{A.1.6.5})$$

and the following formula is used to find the average *precision* metric of the model for all classes:

$$precision_M = \frac{\sum_{i=1}^K \frac{TP_i}{TP_i + FP_i}}{K}. \quad (\text{A.1.6.6})$$

The *recall* metric shows the proportion of correctly identified class examples among all the true class examples processed by the model. To calculate the *recall* in the binary classification problem, the following formula is used [31]:

$$recall = \frac{TP}{TP + FN}. \quad (\text{A.1.6.7})$$

In the classification problem with  $K \geq 3$  classes, to find the *recall* metric of the model for the  $i$ -th class, the following formula is used:

$$recall_i = \frac{TP_i}{TP_i + FN_i}, \quad (\text{A.1.6.8})$$

and the following formula is used to find the average *recall* metric of the model for all classes:

$$recall_M = \frac{\sum_{i=1}^K \frac{TP_i}{TP_i + FN_i}}{K}. \quad (\text{A.1.6.9})$$

The *F1-score* metric is used for comparing classification models. This metric allows reducing model performance estimates obtained by *precision* and *recall* into a one value. In the binary classification problem, formula [32] is used to calculate the *F1-score*:

$$F1\text{-score} = \frac{2 \cdot precision \cdot recall}{precision + recall}. \quad (\text{A.1.6.10})$$

In the classification problem with  $K \geq 3$  classes, to find the *F1-score* metric of the model for the  $i$ -th class, the following formula is used:

$$F1\text{-score}_i = \frac{2 \cdot precision_i \cdot recall_i}{precision_i + recall_i}. \quad (\text{A.1.6.11})$$

and the following formula is used to find the average *F1-score* metric of the model for all classes:

$$F1\text{-score}_i = \frac{\sum_i^K \frac{2 \cdot precision_i \cdot recall_i}{precision_i + recall_i}}{K}. \quad (\text{A.1.6.12})$$

## Приложение Б

(справочное)

### Матрицы неточностей рассмотренных методов



Рисунок Б.1 – Матрица неточностей сверточной нейронной сети, полученная для валидационного набора изображений



Рисунок Б.2 – Матрица неточностей остаточной нейронной сети, полученная для валидационного набора изображений



Рисунок Б.3 – Матрица неточностей метода корреляции изображений, полученная для валидационного набора изображений



Рисунок Б.4 – Матрица неточностей XGBoost с использованием HOG, полученная для валидационного набора изображений

## Приложение В

(справочное)

### Примеры изображений

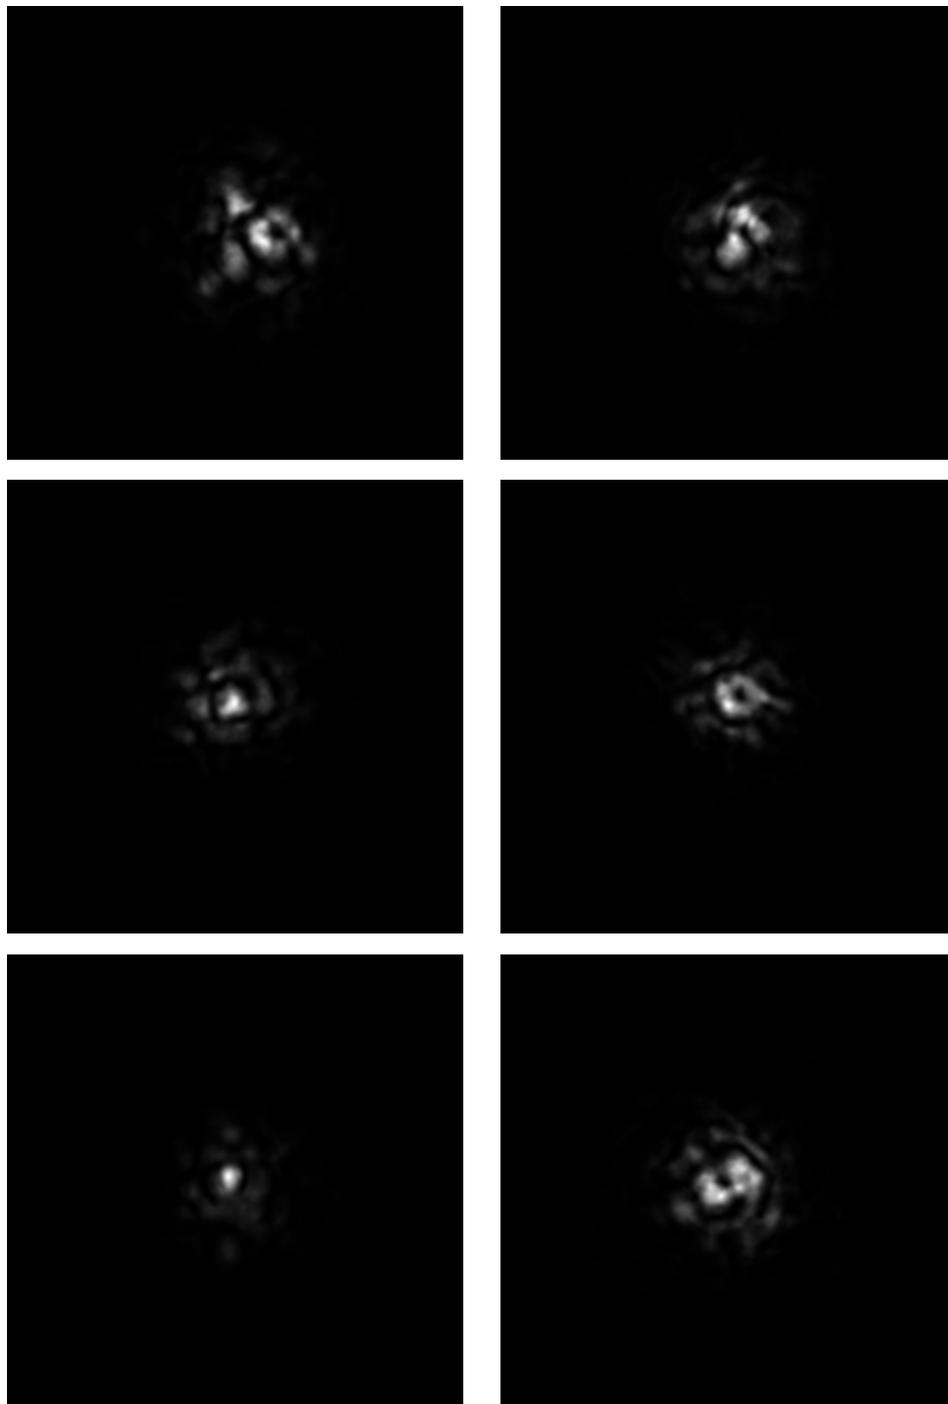


Рисунок В.1 – Примеры изображений, полученных на дистанции 1500 м при

$C_n^2 = 3 \cdot 10^{-14} \text{ м}^{-2/3}$ : слева при ОУМ = 0, а справа при ОУМ = 1

Из рисунка В.1 видно, что при сильной турбулентности формы распределений сильно разрушаются и теряется информация о значении ОУМ.