

Министерство образования и науки Российской Федерации
Федеральное государственное автономное образовательное учреждение
высшего образования
**«НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ ТОМСКИЙ
ПОЛИТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ»**

Инженерная школа ядерных технологий

Направление подготовки: 01.04.02 Прикладная математика и информатика

Отделение экспериментальной физики

МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ

Тема работы
Генерация текста на основе цепей Маркова для чат-бота

УДК 004.773.6:519.876

Студент

Группа	ФИО	Подпись	Дата
0BM91	Курбонов Комрон Сулаймонович		

Руководитель

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

Со-руководитель (по разделу «Концепция стартап-проекта»)

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент	Силифонова Е. В	к.э.н.		

По разделу «Социальная ответственность»

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Ст. преподаватель	Антоневич О А.	доцент		

По английскому языку

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Ст. преподаватель	Сидоренко Т В.			

ДОПУСТИТЬ К ЗАЩИТЕ:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор ШБИП	Трифонов А.Ю.	д.ф-м.н., профессор		

Томск 2021 г.

Министерство образования и науки Российской Федерации
федеральное государственное автономное образовательное учреждение
высшего образования
**«НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ТОМСКИЙ ПОЛИТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ»**

Инженерная школа ядерных технологий

Направление подготовки 01.04.02 «Прикладная математика и информатика»

Отделение экспериментальной физики

УТВЕРЖДАЮ:

Руководитель ООП

_____ Трифонов А.Ю.

(Подпись) (Дата) (Ф.И.О.)

ЗАДАНИЕ

на выполнение выпускной квалификационной работы

В форме:

Магистерской диссертации

Студенту:

Группа	ФИО
0ВМ91	Курбонов Комрон Сулаймонович

Тема работы:

Генерация текста на основе цепей Маркова для чат-бота	
Утверждена приказом директора (дата, номер)	№42-30/с от 11.02.2021

Срок сдачи студентом выполненной работы:	31.05.2021
--	------------

ТЕХНИЧЕСКОЕ ЗАДАНИЕ:

<p>Исходные данные к работе</p> <p><i>(наименование объекта исследования или проектирования; производительность или нагрузка; режим работы (непрерывный, периодический, циклический и т. д.);</i></p>	<p>Вопросы студентов ТПУ, заданные при подготовке и выполнении научно-исследовательской работы в семестре, технологической и производственной практик за 2020-2021 года.</p>
<p>Перечень подлежащих исследованию, проектированию и разработке вопросов</p> <p><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>	<ol style="list-style-type: none"> 1. Провести сравнительный анализ литературы по теме диссертации. 2. Разработать сценарий для чат-бота 3. Программная реализация выгрузки диалогов чат-бота с пользователями. 4. Обработка текста (проверка на наличие орфографических ошибок, ненормативной лексики и т.п.) для генерации диалогов с использованием Марковских цепей 5. Провести тестирование, обучение чат-бота, сделать выводы и проинтерпретировать полученные результаты
<p>Перечень графического материала</p> <p><i>(с точным указанием обязательных чертежей)</i></p>	<ol style="list-style-type: none"> 1. Диаграмма сценария для чат-бота 2. Архитектура приложения, использующего чат-бота на DialogFlow 3. Граф переходов чат-бота между намерениями 4. Марковская цепь для чат-бота
<p>Консультанты по разделам выпускной квалификационной работы</p> <p><i>(если необходимо, с указанием разделов)</i></p>	
Раздел	Консультант
Финансовый менеджмент, ресурсоэффективность и ресурсосбережение	Силифонова Екатерина Валерьевна
Социальная ответственность	Антоневич Ольга Алексеевна
Дата выдачи задания на выполнение выпускной квалификационной работы по линейному графику	15.03.2021

Задание выдал руководитель:

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

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
0ВМ91	Курбонов Комрон Сулаймонович		

ЗАДАНИЕ ДЛЯ РАЗДЕЛА «СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ»

Студенту:

Группа	ФИО
0BM91	Курбонов Комрон Сулаймонович

Школа	Инженерная школа ядерных технологий	Отделение (НОЦ)	Отделение экспериментальной физики
Уровень образования	Магистратура	Направление/специальность	01.04.02 Прикладная информатика и математика

Тема ВКР:

Генерация текста на основе цепей Маркова для чат-бота	
Исходные данные к разделу «Социальная ответственность»:	
1. Характеристика объекта исследования (вещество, материал, прибор, алгоритм, методика, рабочая зона) и области его применения	<p>Объект исследования: Генерация текста на основе цепей Маркова для чат-бота</p> <p>Рабочая зона: стол с компьютером</p> <p>Область применения: корпоративные сети средних и крупных предприятий.</p>
Перечень вопросов, подлежащих исследованию, проектированию и разработке:	
<p>1. Правовые и организационные вопросы обеспечения безопасности:</p> <ul style="list-style-type: none"> – специальные (характерные при эксплуатации объекта исследования, проектируемой рабочей зоны) правовые нормы трудового законодательства; – организационные мероприятия при компоновке рабочей зоны. 	<p>ТК РФ от 30.12.2001 N 197-ФЗ (ред. От 01. 04.2019)</p> <p>ГОСТ 12.2.032 -78 ССБТ. Рабочее место при выполнении работ сидя. Общие эргономические требования.</p> <p>– СП 2.4.3648-20 "Санитарно-эпидемиологические требования к организациям воспитания и обучения, отдыха и оздоровления детей и молодежи".</p>

<p>2. Производственная безопасность: 2.1. Анализ выявленных вредных и опасных факторов 2.2. Обоснование мероприятий по снижению воздействия</p>	<p>Вредные факторы: – Отсутствие или недостаток естественного света; – Недостаточная искусственная освещенность рабочей зоны – Превышение уровня шума; – Отклонение показателей микроклимата; – Наличие электромагнитных излучений; – Умственное перенапряжение; – Монотонность труда; – Перенапряжение анализаторов; – Нервно-психические перегрузки. Опасные факторы: – Повышенное значение напряжение в электрической цепи, замыкание</p>
<p>3. Экологическая безопасность:</p>	<p>– Анализ воздействия на литосферу: образование отходов при утилизации компьютера, люминесцентных ламп.</p>
<p>4 Безопасность в чрезвычайных ситуациях:</p>	<p>– указать наиболее типичную ЧС - пожар разработка превентивных мер по предупреждению ЧС.</p>

Дата выдачи задания для раздела по линейному графику	23.03.2021
--	------------

Задание выдал консультант:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Старший преподаватель ООД	Антоневич Ольга Алексеевна			

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
0ВМ91	Курбонов Комрон Сулаймонович		

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

Студенту:

Группа	ФИО
0BM91	Курбонов Комрон Сулаймонович

Школа	ИЯШТ	Отделение	экспериментальной физики
Уровень образования	Магистратура	Направление/специальность	01.04.02. Прикладная математика и информатика

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

<i>1. Стоимость ресурсов научного исследования (НИ): материально-технических, энергетических, финансовых, информационных и человеческих</i>	Использование информации, представленной в российских и иностранных научных публикациях, аналитических материалах и изданиях, нормативно-правовых документах.
<i>2. Нормы и нормативы расходования ресурсов</i>	
<i>3. Используемая система налогообложения, ставки налогов, отчислений, дисконтирования и кредитования</i>	

Перечень вопросов, подлежащих исследованию, проектированию и разработке:

<i>1. Оценка коммерческого потенциала, перспективности и альтернатив проведения НИ с позиции ресурсоэффективности и ресурсосбережения</i>	Проведение предпроектного анализа. Определение целевого рынка и проведение его сегментирования. Выполнение SWOT-анализа проекта.
<i>2. Определение возможных альтернатив проведения научных исследований</i>	Определение целей и ожиданий, требований проекта. Определение заинтересованных сторон и их ожиданий.
<i>3. Планирование процесса управления НИИ: структура и график проведения, бюджет, риски.</i>	Составление календарного плана проекта. Определение бюджета НИИ
<i>4. Определение ресурсной, финансовой, экономической эффективности.</i>	Проведение оценки экономической эффективности исследования.

Перечень графического материала (с точным указанием обязательных чертежей):

<ol style="list-style-type: none"> 1. Оценка конкурентоспособности технических решений 2. Матрица SWOT 3. Оценка готовности проекта к коммерциализации 4. Календарный план-график и бюджет НИИ 5. Оценка ресурсной, финансовой и экономической эффективности НИИ 6. Сравнительная эффективность разработки
--

Дата выдачи задания для раздела по линейному графику

Задание выдал консультант:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент	Силифонова Е.В.	к.э.н		

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
0BM91	Курбонов Комрон Сулаймонович		

ПЛАНИРУЕМЫЕ РЕЗУЛЬТАТЫ ОБУЧЕНИЯ ПО ООП

Код результата	Результат обучения
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
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
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 организовывать 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 определять и реализовывать приоритеты собственной деятельности и способы ее совершенствования на основе самооценки

Реферат

Выпускная квалификационная работа: 126 листов, 26 рисунков, 34 таблицы, 41 использованных литературных источников.

Ключевые слова: чат-бот, обработка естественного языка, система сквозной разработки, цепи Маркова, Python.

Объект исследования: чат-бот.

Цель работы: разработать математическую модель для автоматизированной генерации ответов чат-бота.

Работа включает: введение, пять разделов, список публикаций студента, а также список использованных литературных источников.

В разделе 1 «Обзор литературы» приведен краткий обзор литературы, необходимый для дальнейшей работы, сформулирована цель и задачи работы.

В разделе 2 «Теоретические аспекты» рассмотрены теоретические аспекты разработки чат-ботов, проведен анализ существующих аналогов и технологий для их разработки.

В разделе 3 «Программирование чат-бота» приведено описание процесса разработки, в том числе: подготовка данных для машинного обучения, разработка модели, разработка и тестирование прототипа чат-бота.

В разделе 4 «Социальная ответственность» оценены риски и опасности для здоровья и окружающей среды и рассмотрены способы их минимизации.

В разделе 5 «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение» рассмотрена экономическая составляющая работы. Посчитаны затраты на реализацию и изучены конкуренты на рынке, а также посчитана рентабельность проекта.

Definitions

Application programming interface (API) – is a computer interface which defines interactions between multiple software intermediaries. It defines the kinds of calls or requests that can be made, how to make them, the data formats that should be used, the conventions to follow, etc.

Chat-bot– a program that simulates a person’s speech behavior when communicating with one or more interlocutors.

Context – Can be used “remember” parameter values, so they can be passed between intents.

Entities – Each intent parameter has a type, called the *entity type*, which dictates exactly how data from an end-user expression is extracted.

End-to-End System – a full package of machine learning system that processes data, learns from it and deliver user-friendly results.

Intent – An intent categorizes an end-user's intention for one conversation turn. When an end-user writes or says something, referred to as an end-user expression, matches the end-user expression to the best intent in your agent. Matching an intent is also known as intent classification.

Natural language – a complex system of rules in accordance with which speech activity occurs, i.e. generation and understanding of texts.

Natural language processing – one of the areas of artificial intelligence and mathematical linguistics, which is studying the problems of computer analysis and synthesis of natural languages.

Neural network –a network that simulates human or animal brain with lots of densely interconnected artificial neurons, so that a computer program can learn things, recognize patterns and make decisions in a humanlike way.

Tokenization – the process of demarcating and possibly classifying sections of a string of input characters.

Оглавление

1. Литературный обзор.....	13
2. Генерация текста с использованием цепей Маркова	16
3. Практическая часть	18
3.1. Формирование корпуса вопросов-ответов.....	18
3.2. Программная реализация и развитие чат-бота.....	19
3.3. Интеграция чат-бота с мессенджером Telegram.....	22
4. СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ.....	24
Правовые и организационные вопросы обеспечения безопасности	25
Эргономические требования к рабочему месту	25
4.1 Производственная безопасность	26
4.1.1 Отклонение показателей микроклимата в помещении	28
4.1.2 Недостаточная освещенность рабочей зоны	31
4.1.3 Повышенное значение напряжения в электрической цепи, замыкание которой может пройти через тело человека.....	35
4.2 Экологическая безопасность	37
4.3 Безопасность в чрезвычайных ситуациях	38
4.4 Выводы по разделу «Социальная безопасность»	40
ФИНАНСОВЫЙ МЕНЕДЖМЕНТ, РЕСУРСОЭФФЕКТИВНОСТЬ И РЕСУРСОСБЕРЕЖЕНИЕ	41
Предпроектный анализ	41
Потенциальные потребители результатов исследования.....	41
Анализ конкурентных технических решений с позиции ресурсоэффективности и ресурсосбережения	42
SWOT-анализ.....	44
Оценка готовности проекта к коммерциализации	46
Методы коммерциализации результатов научно-технического исследования ..	48
Инициация проекта	49
Планирование управления научно-техническим проектом.....	51
1.1.2 Иерархическая структура проекта.....	51
1.1.3 План проекта	51
Бюджет научного исследования	71

Специальное оборудование для научных(экспериментальных)работ	71
Основнаязаработная плата	71
Дополнительная заработная плата	73
Отчисления на социальные нужды	73
Прочие прямые расходы	74
Накладные расходы	74
1.1.4 План управления коммуникациями проектами	75
1.1.5 Реестр рисков проекта	75
1.2 Определение ресурсной (ресурсосберегающей), финансовой, бюджетной, социальной и экономической эффективности исследования	76
1.2.2 Оценка сравнительной эффективности исследования	82
Список публикаций студента	85
Заключение	86
Список литературы	87
Приложение А	92
Приложение 1. Список вопросов и ответов	110
Приложение 2. Код программы для обработки и генерации текста	113
Приложение 3. Косинусное сходство между оригинальным и сгенерированными предложениями	119

Чат-боты – это автоматизированные системы, которые помогают пользователям находить ответы на их запросы. Для предприятий и организаций они предоставляют современный способ связи со своими сотрудниками, клиентами. Чат-боты предоставляют удобный интерфейс для получения ответов на запросы без звонка по телефону или электронной почты.

Чат-боты применяются практически во всех сферах жизнедеятельности, таких как услуги, коммерция, развлечения и консультирование и могут быть разделены на следующие группы: отвечающие на вопросы, ориентированные на выполнение задач, социальные боты. В зависимости от группы к современным чат-ботам предъявляют различные требования, в частности: иметь разговорные способности, представлять семантически правильную информацию и содержательные ответы, иметь возможность для обучения для конкретной предметной области. Для соответствия этим требованиям в чат-боты могут быть заложены различные модели генерации ответов, например, модели на основе шаблона, целевого поиска или генеративного подхода.

Цель работы – разработать математическую модель для автоматизированной генерации ответов чат-бота.

Для достижения поставленной цели были сформулированы следующие задачи:

- 1) Сформировать корпус вопросов-ответов.
- 2) Разработать сценарий для чат-бота.
- 3) Программно реализовать выгрузку диалогов чат-бота с пользователями.
- 4) Сгенерировать тексты ответов на запросы пользователей с предварительной обработкой (проверка на наличие орфографических ошибок, ненормативной лексики и т.п.).

1. Литературный обзор

Чат-боты – это автоматизированные системы, которые помогают пользователям находить ответы на их запросы. Для предприятий и организаций они предоставляют современный способ связи со своими сотрудниками, клиентами. Чат-боты предоставляют удобный интерфейс для получения ответов на запросы без звонка по телефону или электронной почты.

Чат-боты применяются практически во всех сферах жизнедеятельности, таких как услуги, коммерция, развлечения и консультирование и могут быть разделены на следующие группы:

- а) отвечающие на вопросы,
- б) ориентированные на выполнение задач,
- в) социальные боты.

Боты для ответов на вопросы – это чат-боты, основанные на знаниях, которые отвечают на запросы пользователей, анализируя основную информацию, собранную из различных источников.

Боты, ориентированные на задачи – это чат-боты, ориентированные на решение конкретной проблемы (например, бронирование билетов).

Социальные боты – общаются с другими пользователями и дают им рекомендации.

К современным чат-ботам предъявляют следующие требования:

Иметь разговорные способности. Поддержание беседы – это основа чат-бота. Чат-бот должен генерировать точные и значимые ответы, определять намерения (intents), сущности (entities) и контекст (contexts), а не давать просто односложные ответы «да» или «нет».

Представлять семантически правильную информацию. Семантика помогает передать правильное значение слова в соответствии с контекстом предложения. Например, слово «Питер» может иметь различное семантическое значение: город или имя.

Предоставлять содержательные ответы. При генерации ответа чат-бот

должен не только давать ответ, который является семантически правильным, он также должен предоставлять важные детали для облегчения понимания. Например, в ответ на вопрос «*Какой сегодня день?*» семантически правильный ответ – «*пятница*», а значимый ответ – «*пятница, 21 мая*».

Иметь возможность для обучения для конкретной предметной области. Чат-бот, ориентированный на предметную область, должен быть обучен на конкретном корпусе вопросов-ответов.

Для взаимодействия с пользователем и поддержания продолжительных бесед чат-бот, как правило, содержит следующие основные компоненты: а) компонент обработки ввода, б) компонент понимания языка, в) компонент генерации ответа (рисунок 1).

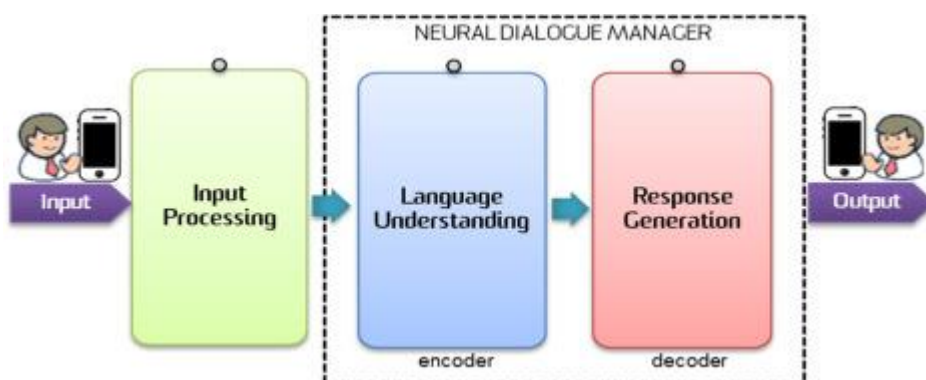


Рисунок 1.1 Основные компоненты чат-бота [6].

Компонент обработки ввода. Этот компонент обрабатывает вводимые пользователем данные (перевод текста в нижний регистр, фильтрация знаков препинания, удаление стоп-слов, сегментация слов).

Компонент понимания языка. Этот компонент понимает вопрос пользователя, принимая в качестве входных данных сегменты слова (токенизация, распознавание именованных объектов, лемматизация, идентификация контекста, анализ тональности, классификация запросов).

Компонент генерации ответа. Этот компонент генерирует ответ на вопрос пользователя. При этом ответ может быть сформирован на

- а) основе шаблона – стандартный запрос к корпусу вопросов-ответов,
- б) целевого поиска – семантический запрос в сети Интернет с последующей

обработкой,

в) генеративного подхода – синтеза знаний для генерации ответов на лету.

Остановим подробнее на последнем способе генерации ответов.

В статье [3] предложен метод конвейера, ориентированный на задачи с использованием нейронных сетей и глубокого обучения. Однако у этих моделей есть недостатки – большие данные для обучения, участие экспертов для правильного обучения. В работе [5] предложен блок генерации вопросов, который генерирует последующие вопросы с использованием *пословного вектора*. В работе [6] предложена модель Seq2Seq, которая представляет полно связанную нейронную сеть для генерации ответов. В исследованиях [8, 9] предложено для генерации ответов использовать модель цепи Маркова. В магистерской работе [16] предложен чат-бот, встраиваемый в корпоративные системы, реализованный с использованием только открытых библиотек.

2. Генерация текста с использованием цепей Маркова

Большинство современных методов обработки естественного языка существенно зависят от данных. Для обучения моделей машинного обучения требуется значительный объем данных, а в некоторых сценариях данных может оказаться недостаточно.

В данной работе мы предлагаем использовать метод генерации новых ответов на запросы пользователей (предложений) для расширения обучающих данных. Наш подход использует цепи Маркова.

Цепь Маркова – это статистическая модель, которую можно использовать для последовательной обработки текстов. Цепи позволяют вычислить вероятность наступления наблюдаемых событий (в нашем случае, какое слово лучше подходит в определенном месте предложения) [9].

Последовательность дискретных случайных величин $\{X_n\}$, $n \geq 0$ будем называть простой цепью Маркова (с дискретным временем), если

$$\mathbf{P}(X_{n+1}=i_{n+1} | X_n=i_n, X_{n-1}=i_{n-1}, \dots, X_0=i_0) = \mathbf{P}(X_{n+1}=i_{n+1} | X_n=i_n). \quad (1)$$

Формула (1) задает условное распределение последующего состояния цепи Маркова, которое зависит только от текущего состояния и не зависит от всех предыдущих состояний. При этом $\{X_n\}$ называют пространством состояний цепи, а n – номером шага. Матрица $P_{ij}(n) = \mathbf{P}(X_{n+1}=j | X_n=i)$ называется переходной матрицей вероятностей на n -ом шаге, а вектор $\mathbf{p}=(p_1, p_2, \dots)$ – начальным распределением цепи Маркова. Матрица $P_{ij}(n)$ является стохастической и для нее выполняется условие нормировки.




Рисунок 1.2 Цепь Маркова с четырьмя состояниями

Алгоритм генерации текста.

1. Исходный текст разбить на слова.
2. Все слова, которые стоят рядом, объединить в пары.
3. Используя эти пары, составить словарь цепочек, где указано первое слово и все слова, которые могут идти после него.
4. Выбрать случайное слово для начала работы.
5. Задать длину желаемого текста и выбрать случайное слово для начала работы.

Для иллюстрации работы данного алгоритма мы использовали в качестве исходного текста первые два абзаца из данного раздела и сгенерировали длиной 6 слов. В результате получили фразу «ответов на запросы пользователей (предложений) для».

Полный код на Python доступен по ссылке <https://colab.research.google.com/drive/1Xep7jg14Xs1vu0WeawLjrkuipjHymkMx#scrollTo=daRj6wDKu9rk>

Далее данный алгоритм можно применить циклически и получить новую фразу.

Для определения сходства между двумя фразами могут быть использованы различные расстояний, например, расстояние Левенштейна, N-граммное расстояние и косинусное расстояние.

Расстояние Левенштейна измеряет по модулю разность между двумя последовательностями символов (словами). Это расстояние определяется как минимальное количество односимвольных операций (вставка, удаление, замена), необходимых для превращения одной последовательности символов в другую. Для вычисления N-граммного расстояния – требуется разбить строку на подстроки длины N и подсчет количества совпадающих подстрок. Для вычисления косинусного расстояния требуется преобразование двух текстовых строк X, Y в два бинарных вектора: если слова совпадают, то элементы векторов равны 1, иначе 0. Окончательно формула будет выглядеть:

$$\cos(X, Y) = \frac{\sum_{i=1}^n (X_i - Y_i)}{\sqrt{\sum_{i=1}^n (X_i)^2} \sqrt{\sum_{i=1}^n (Y_i)^2}} \quad (2)$$

Заметим, что для применения формулы (2) требуется предварительная предобработка текста (лемматизация), то есть приведение текста к словарной форме.

В русском языке словарными принято считать следующие формы:

- для существительных – именительный падеж, единственное число;
- для прилагательных – именительный падеж, единственное число, мужской род;
- для глаголов, причастий, деепричастий – глагол в инфинитиве.

3. Практическая часть

3.1. Формирование корпуса вопросов-ответов

В качестве предметной области работы чат-бота мы выбрали образовательную деятельность и разработали интеллектуального помощника для студентов и преподавателей ТПУ.

Для формирования корпуса вопросов-ответов мы использовали вопросы студентов ТПУ, которые они задавали при подготовке и выполнении научно-исследовательской работы в семестре, технологической и производственной практик за 2020-2021 года, а для формулирования ответов мы использовали нормативные документы образовательной деятельности [12]. Приведем в качестве примера один вопрос и варианты ответа на него:

Вопрос	Ответы	
Какие разделы должны быть в магистерской диссертации?	1	Обычно диссертация включает 10 разделов: Содержание, Аннотация, Введение, Постановка задачи, 1. Обзор известных методов и средств решения проблемы, 2. Исследование и построение решения, 3. Описание практической части, Заключение, Список цитируемой литературы и Приложение(я).
	2	Необходимые разделы диссертации перечислены в Регламенте, на странице
	3	Основные разделы диссертации это 1. Обзор известных методов и средств решения проблемы, 2. Исследование и построение решения, 3. Описание практической части. Более подробно смотри регламент на странице <###>

	4	Пояснительная записка к диссертации включает 10 основных разделов, подробнее описание смотри в регламента на странице .
	5	Как правило, диссертация включает 10 основных разделов, подробнее описание смотри в регламента на странице .

Мы заложили в чат-бот сценарий, в котором диалог осуществляется в зависимости от выбора пользователя: например, *электронное согласование* или *оформление документов на бумажном носителе*. От этого зависит, что чат-бот предложит дальше: *адрес сайта для загрузки документов* или *номер аудитории/корпус и приёмные часы для визирования документа*.

С полным списком вопросов и ответов можно ознакомиться в Приложении 1.

3.2. Программная реализация и развитие чат-бота

Для создания чат-бота мы использовали облачный сервис распознавания естественного языка Dialogflow (<https://dialogflow.cloud.google.com/>).

Для начала работы сервисом мы провели языковые настройки чат-бота (в терминах Dialogflow чат-бот называется *агентом*) и добавили в него вопросы (Intents – намерения, цели) и тренировочные ответы (Training phrases) из нашего корпуса вопросов-ответов, а также настроили сущности (Enteties) и контексты (Contexts) для ведения диалогов.

Для выгрузки, обработки текста и генерации текста мы использовали язык Python. Запуск выполняется с помощью следующих команд с ключами.

Для проверки базы ответов на наличие ненормативной лексики:

```
python3 main.py -task profanity
```

Для проверки на синтаксические ошибки:

```
python3 main.py -task spellchecking
```

Генерация текста на основе существующих диалогов:

```
python3 main.py -task generate
```

Полный код программы приведен в Приложении 2.

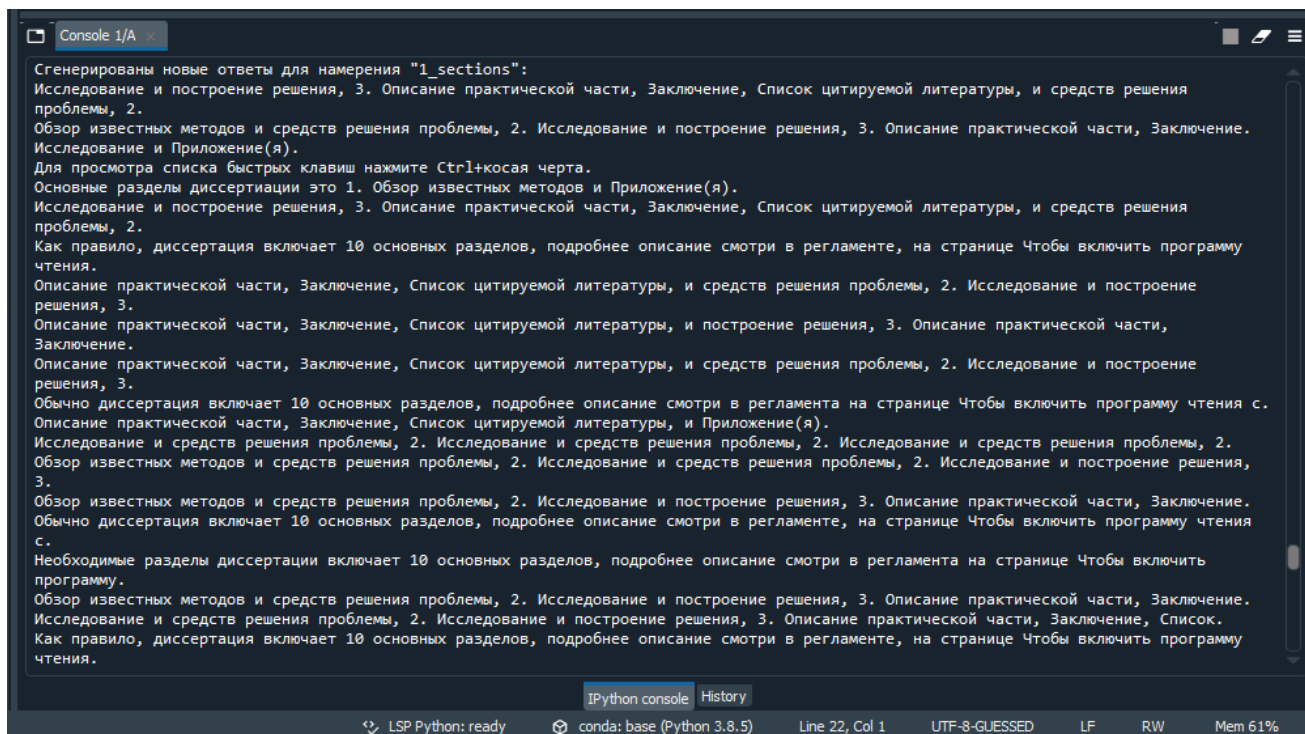


Рисунок 3.5. Пример сгенерированного текста на основании намерения

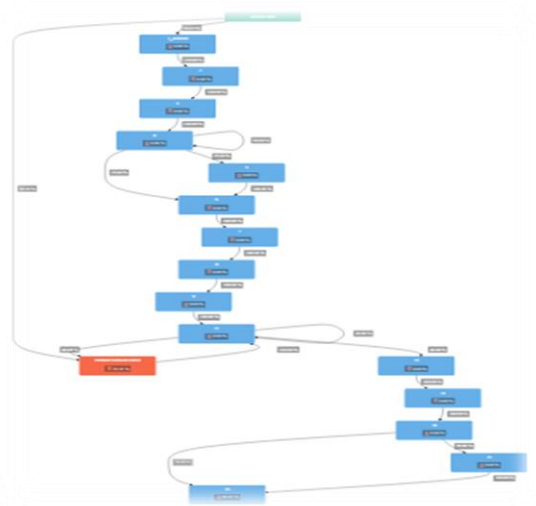
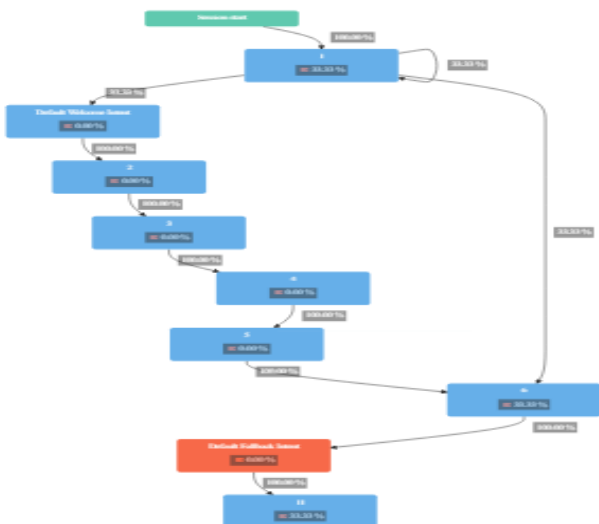
Для оценки качества между оригинальным и сгенерированными предложениями мы использовали косинусное сходство (2). Код программы приведен в Приложении 3.

В таблице 2 приведено косинусное сходство между оригинальным X и сгенерированными предложениями (намерениями) $Y_i, i=1, 2, \dots, 20$.

В Dialogflow встроен инструмент обучения для анализа, импорта и экспорта проведенных диалогов. По умолчанию обучение выполняется автоматически при каждом сохранении чат-бота на стороне сервера. Диалоги можно отобразить в виде диаграммы (рисунок 3.6). Прямоугольники на графе переходов обозначают намерения, при этом зеленым цветом обозначено – начальное намерение (запуск чат-бота), синим – намерения в ходе диалога, стрелки — это переходы от одного намерения к другому, красным прямоугольником обозначено резервное намерение (чат-бот задает уточняющий вопрос), цифры (в процентах) на стрелках соответствуют вероятности перехода от одного намерения (родительского) к другому (дочернему).

Таблица 2. Косинусное сходство между оригинальным и сгенерированными предложениями

N		Cos(X, Yi)
3	Intent_4	0.444750
1	Intent_2	0.470871
10	Intent_11	0.518563
9	Intent_10	0.668648
7	Intent_8	0.676123
8	Intent_9	0.801388
4	Intent_5	0.816497
11	Intent_12	0.816497
2	Intent_3	0.836242
5	Intent_6	0.840168
12	Intent_13	0.858116
13	Intent_14	0.930949
14	Intent_15	0.945905
15	Intent_16	0.948683
0	Intent_1	0.955330
6	Intent_7	0.968246



а б

Рисунок 3.6. Диаграмма переходов чат-бота между намерениями:
а) без обучения человеком, б) после обучения человеком

Также обучение можно выполнить в ручном режиме (рисунок 3.7), для этого нужно выбрать диалог и расставить метки (правильно, неправильно).

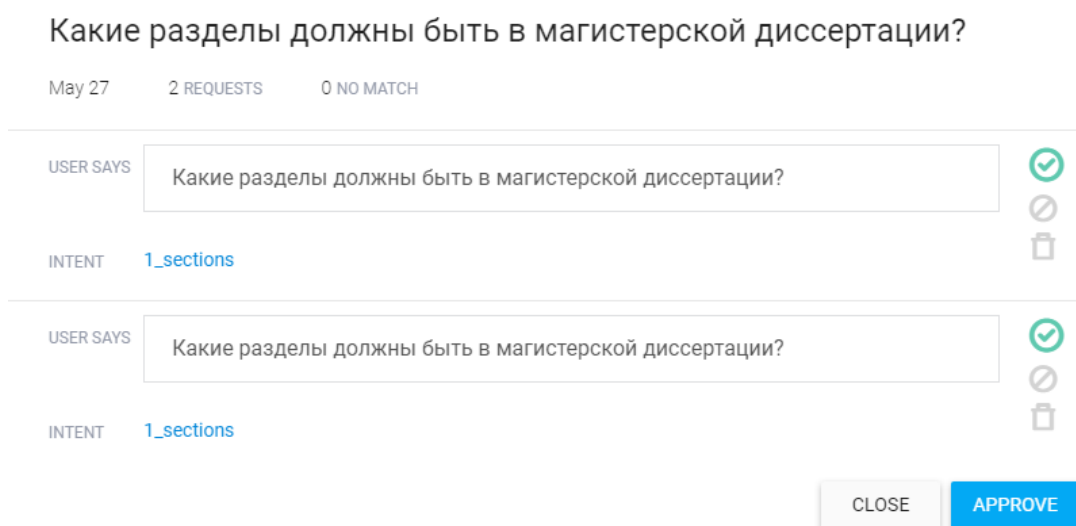


Рисунок 3.7. Список редактируете отображаемые

Как видно из рисунка 3.6 диаграмма переходов после обучения в ручном режиме изменилась.

3.3. Интеграция чат-бота с мессенджером Telegram

Разработанный чат-бот может быть интегрирован в корпоративную систему различными способами. Возможные способы интеграции чат-бота приведены на рисунке 3.1.

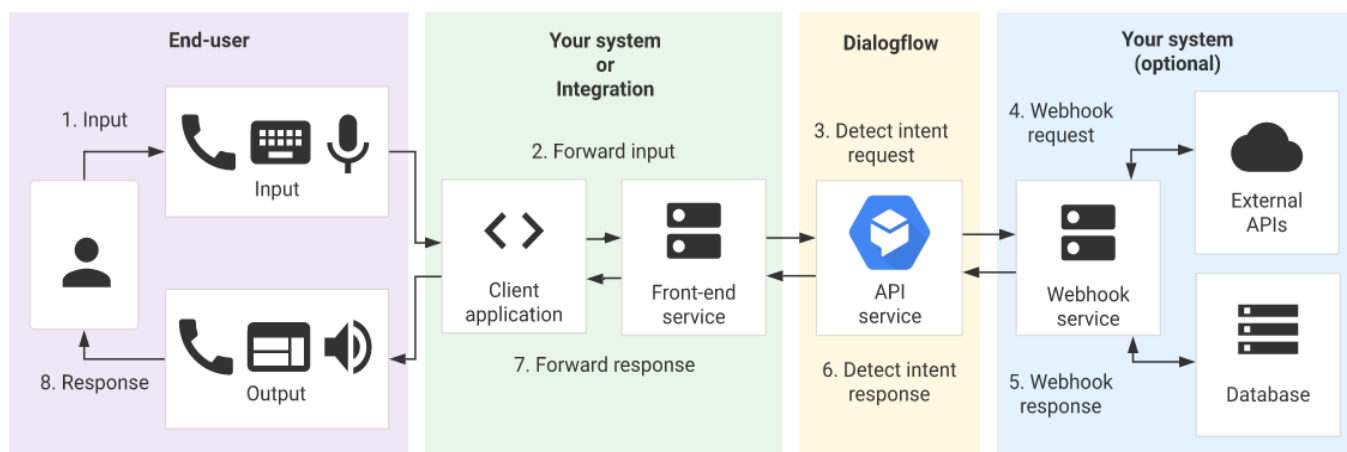


Рисунок 3.1. Диаграмма сценария для чат-бота

Для практического использования разработанного чат-бота мы провели его интеграцию с мессенджером Telegram.

Для интеграции чат-бота в Telegram необходим аккаунт. Далее перечислены основные пункты для создания чат-бота:

1. Открыть диалог с BotFather и начать создание – `/start`,
2. Создать нового чат-бота командой `/newbot`,
3. Внести оригинальное название чат-бота (в нашем случае TPU_VKR),
4. Получить сгенерированный маркер доступа (access token).

Маркер доступа позволяет идентифицировать пользователя и содержит информацию о безопасности сеанса. Маркер вводится при установке интеграционного процесса в Dialogflow, после чего ссылка на созданного бота появляется в диалоге с BotFather. Данная ссылка служит приглашением к диалогу с чат-ботом.

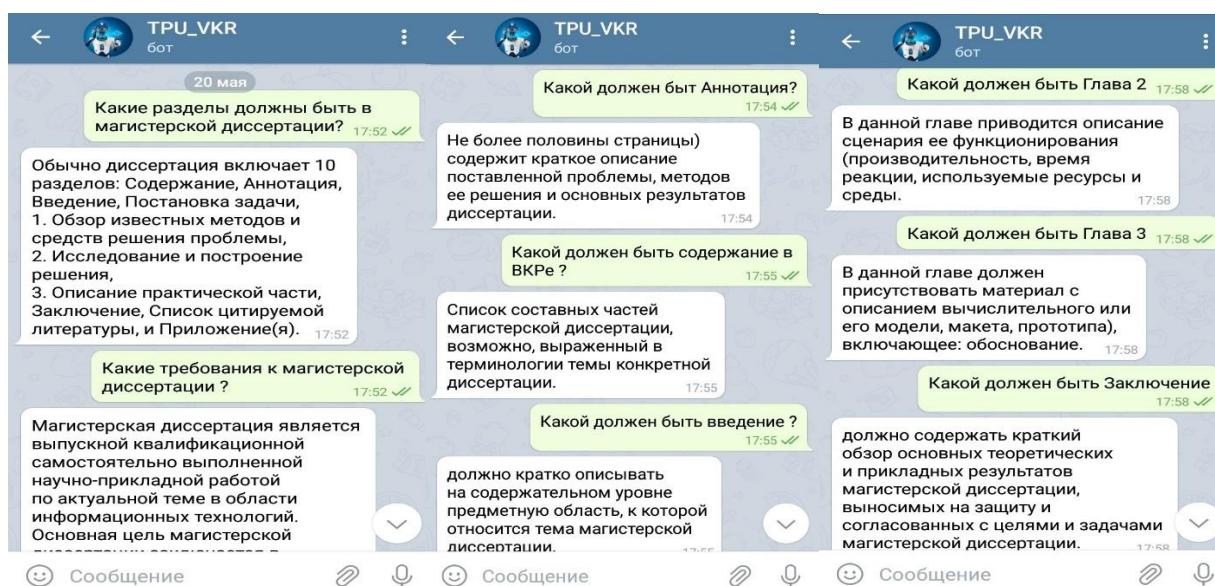


Рисунок 3.17. Пример диалогов через мессенджер Telegram

Как видно из рисунка 3.17 при вводе вопросов (зеленые поля) пользователь допускает ошибки, однако разработанный чат-бот корректно отвечает на вопросы.

4. СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ

Большинство современных методов обработки естественного языка существенно зависят от данных. Для обучения моделей нейронных сетей требуется значительный объем данных, а в некоторых сценариях данных может оказаться недостаточно.

В данной работе мы предлагаем использовать метод генерации новых ответов на запросы пользователей (предложений) для расширения обучающих данных. Наш подход использует цепи Маркова

В разделе социальной ответственности рассмотрены вредные и опасные факторы рабочего места, негативно влияющие на организм человека, также рассмотрены вопросы, связанные с организацией рабочего места и условий, в которых реализуется данная исследовательская работа. Также указан характер вредного воздействия данных факторов на организм человека и последствия их длительного и чрезмерного воздействия.

Также рассмотрены вопросы, связанные с организацией рабочего места и условий, в которых будет реализовываться проект, описанный в данной работе, а именно, обработка данных полученных в полученных на рабочем месте, в соответствии с нормами производственной санитарии, техники безопасности и охраны труда и окружающей среды.

Рабочим местом является аудитория 427а 10-ого корпуса Томского политехнического университета по адресу проспект Ленина 2, рабочей зоной является стол с компьютером.

В рамках данной работы необходимо разработать математическую модель для автоматизированной генерации ответов чат-бота. Чат-бот может быть использован в предприятиях для облегчения рутинных задач, таких как: отправка писем по электронной почте, электронный документооборот, поиск в интернете и т.д.

Правовые и организационные вопросы обеспечения безопасности

Эргономические требования к рабочему месту

В процессе работы, все используемые предметы должны находиться в зоне досягаемости. Оптимальное размещение предметов труда и документации в зонах досягаемости приведено на рисунке 4.1.




Рисунок 4.1 –Зона досягаемости. а – зона максимальной досягаемости;
б – зона досягаемости пальцев при вытянутой руке;
в – зона легкой досягаемости ладони;
г – оптимальное пространство для грубой ручной работы;
д – оптимальное пространство для тонкой ручной работы [23].

Поскольку рабочее положение за компьютером является сидячим, то важными элементами, обеспечивающими комфортное положение сотрудника (студента), будут являться стол и стул.

В соответствии с ГОСТ 12.2.032-78. «Система стандартов безопасности труда. Рабочее место при выполнении работ сидя» форма рабочей поверхности устанавливается с учетом характера выполняемой работы. Таким образом рабочий стол офисного сотрудника (студента) может быть любой конструкции, отвечающей современным требованиям эргономики и позволяющей удобно разместить на рабочей поверхности оборудование с учетом его количества, размеров и характера

выполняемой работы.

Также для более быстрого считывания информации, следует располагать экран в вертикальной плоскости под углом 15 градусов от нормальной линии взгляда и в горизонтальной плоскости под углом 15 градусов от сагиттальной плоскости [3]. В данный момент функцию рабочего стула на исследуемом рабочем месте выполняет кресло, которое обеспечивает длительное поддержание основной рабочей позы в процессе трудовой деятельности. Конструкция регулируемого кресла соответствует требованиям ГОСТ 21889-76 «Система «человек-машина. Кресло человека-оператора. Общие эргономические требования» [4].

Рабочей зоной выполнения проекта является помещение со следующими характеристиками:

- Ширина помещения – 5 м, длина – 6 м, высота – 3,5 м;
- Площадь помещения – 30 м²;
- Объем помещения – 105 м³.

В данном помещении оборудовано 8 рабочих мест, максимальное количество студентов в одну смену – 6. В среднем на одного студента приходится 5 м² площади и около 17,5 м³ объема помещения, что соответствует требованиям СП 118.13330.2012 [5].

Также в комнате имеется естественная вентиляция – вытяжное вентиляционное отверстие, дверь, окно, щели. Освещение в помещении комбинированное. Оно включает в себя искусственное (люминесцентные лампы типа ЛБ или лампы накаливания) и естественное.

Из выше приведенного исследования, можно сделать вывод, что по помещению и условия труда удовлетворяют нормативным требованиям.

4.1 Производственная безопасность

Данная работа требует долгого нахождения за компьютером. Таким образом, согласно ГОСТ 12.0.003-2015 «Система стандартов безопасности труда (ССБТ). Опасные и вредные производственные факторы. Классификация» можно выделить вредные и опасные факторы, которые представлены в таблице 1 [6].

Также, при работе с электрическими приборами возникают вредные и опасные

факторы, их перечень приведен в таблице 1.

Таблица 4.1–Опасные и вредные факторы при работе с электроприборами

Факторы (ГОСТ 12.0.003-2015)	Этапы работ			Нормативные документы
	Разработка	Изготовление	Эксплуатация	
Отклонение показателей микроклимата в помещении	-	-	+	СанПиН 2.2.4.548–96 «Гигиенические требования к микроклимату производственных помещений».
Превышение уровня шума	-	-	+	ГОСТ 12.1.003-2014 ССБТ. Шум. Общие требования безопасности.
Умственное перенапряжение	-	-	+	Гост 12.0.003-2015. Межгосударственный стандарт. Система стандартов безопасности труда
Монотонность труда	-	-	+	Гост 12.0.003-74 группа т58. Межгосударственный стандарт. Система стандартов безопасности труда
Нервно-психические перегрузки				
Перенапряжение анализаторов				
Недостаток естественного света	-	-	+	СП 52.13330.2016 «Естественное и искусственное освещение.» Актуализированная редакция СНиП 23-05-95*.
Недостаточная освещенность рабочей зоны	-	-	+	
Повышенное значение напряжения в электрической цепи, замыкание которой может пройти через тело человека	-	-	+	СанПиН 2.2.4.3359-16 "Санитарно-эпидемиологические требования к физическим факторам на рабочих местах" .
Наличие электромагнитных излучений	-	-	+	ГОСТ 12.1.019-2017 МЕЖГОСУДАРСТВЕННЫЙ СТАНДАРТ. Система стандартов безопасности труда. ЭЛЕКТРОБЕЗОПАСНОСТЬ. Общие требования и номенклатура видов защиты. ГОСТ 12.1.004-91. Группа Т58 МЕЖГОСУДАРСТВЕННЫЙ СТАНДАРТ. Система стандартов безопасности труда. ПОЖАРНАЯ БЕЗОПАСНОСТЬ. ГОСТ 12.1.010-76. Группа Т58 МЕЖГОСУДАРСТВЕННЫЙ СТАНДАРТ. Система стандартов безопасности труда. ВЗРЫВОБЕЗОПАСНОСТЬ. Общие требования.

Анализ опасных и вредных производственных факторов

В соответствии с последовательностью в таблице 1 производится анализ выявленных вредных и опасных факторов по отдельности.

4.1.1 Отклонение показателей микроклимата в помещении

Микроклимат является важной характеристикой производственных помещений. В организме человека происходит непрерывное выделение тепла. Одновременно с процессами выделения тепла происходит непрерывная теплоотдача в окружающую среду.

Нарушение теплового баланса в условиях высокой температуры может привести к перегреву тела, и как следствие к тепловым ударам с потерей сознания. В условиях низкой температуры воздуха возможно переохлаждение организма, могут возникнуть простудные болезни, радикулит, бронхит и другие заболевания. Показателями, которые характеризуют микроклимат рабочей зоны, являются:

- температура воздуха, °С;
- относительная влажность воздуха, %;
- скорость движения воздуха, м/с.

Оптимальные значения этих характеристик зависят от сезона (холодный, тёплый), а также от категории физической тяжести работы. Для математика и программиста она является лёгкой (1а), так как работа проводится сидя, без систематических физических нагрузок.

Оптимальные показатели микроклимата рабочей зоны, согласно СанПиН 2.2.4.548 - 96, представлены в таблице 5, допустимые – в таблице 2, а допустимые в таблице 3.

– Таблица 2 – Оптимальные показатели микроклимата

Период года	Температура воздуха, °С	Относительная влажность воздуха, %	Скорость движения воздуха, м/с
Теплый	23-25	40-60	0,1
Холодный	22-24	40-60	0,1

Таблица 3 – Допустимые показатели микроклимата

	Температура воздуха, °С		Скорость движение воздуха, м/с
--	-------------------------	--	--------------------------------

Период года	Диапазон ниже оптимальных величин	Диапазон выше оптимальных величин	Относительная влажность воздуха, %	Диапазон ниже оптимальных величин	Диапазон выше оптимальных величин
Теплый	21,0-22,9	24,1-25,0	15-75	0,1	0,2
Холодный	20,0-21,9	25,1-28,0	15-75	0,1	0,1

Мероприятия по доведению микроклиматических показателей до нормативных значений включаются в комплексные планы предприятий по охране труда.

Рабочая аудитория, в которой проводилась работа за компьютером по написанию ВКР находится в учебном 10 – ом корпусе ТПУ. Температура находилась в оптимальных пределах 22-24 оС, относительная влажность воздуха в пределах 40 – 60%, скорость движения воздуха не более 0,2 м/с.

Важнейшими способами регулирования микроклимата в производственных помещениях и в зонах рабочих мест являются:

- Кондиционирование и вентиляция воздуха помещений;
- Отопление;

Кондиционер в помещении отсутствовал. Поэтому для поддержания нужной температуры необходимо было проветривать помещение.

Вывод: Условия микроклимата соответствуют нормам СанПиН 2.2.4.548–96.

Превышение уровня шума

Основным источником шума в помещении при написании магистерской диссертации выступает компьютер. Согласно ГОСТ 12.1.003-2014 ССБТ «Шум. Общие требования безопасности» при выполнении основной работы на ПК во всех учебных помещениях уровень шума на рабочем месте не должен превышать 50 дБА.

Повышенный шум на рабочем месте оказывает вредное влияние на организм работника в целом, вызывая неблагоприятные изменения в его органах и системах. Длительное воздействие такого шума способно привести к развитию у работника потери слуха, увеличению риска артериальной гипертензии, болезней сердечно-

сосудистой, нервной системы и др. При этом специфическим клиническим проявлением вредного действия шума является стойкое нарушение слуха (тугоухость), рассматриваемое как профессиональное заболевание [8].

Таким образом, при значениях выше допустимого уровня необходимо предусмотреть защиту от шумов, а именно заключение вентиляторов в защитный кожух и установление их внутри корпуса ЭВМ.

Также, для снижения уровня шума стены и потолок помещений, где установлены компьютеры, могут быть облицованы звукопоглощающими материалами.

Ноутбук Asus, на котором была выполнена магистерская диссертация, в условиях максимальной нагрузки на процессор и видеокарту имеет уровень шума вентилятора около 38 дБ, что не превышает предельно допустимое значение: 50дБА.

Вывод: Условия труда на рабочем месте по шумовому фактору соответствует допустимым нормам, поэтому использование дополнительных средств защиты можно опустить.

4.3 Электромагнитное излучение

При длительном постоянном воздействии электромагнитного поля (ЭМП) радиочастотного диапазона при работе за ПЭВМ на организм человека наблюдаются нарушения сердечно-сосудистой, дыхательной и нервной систем, характерны головная боль, утомляемость, ухудшение самочувствия, гипотония, изменение проводимости сердечной мышцы.

Для снижения вредного воздействия ЭМП пользователю необходимо:

- Соблюдать расстояние от глаз до монитора от 0.5 до 1 метра;
- Рекомендуется пользоваться жидкокристаллическими мониторами вместо устаревших устройств с электронно-лучевой трубкой;
- Важно уменьшать количество времени, проводимого за компьютером до установленных норм и делать перерывы в работе для отдыха;

— Применение средств индивидуальной защиты, например очки со специальным покрытием.

Персональный компьютер имеет сразу два источника электромагнитного излучения: монитор и системный блок. На рабочем месте используются современная техника с пониженным уровнем излучения. Помимо этого, при написании магистерской диссертации соблюдались все вышеперечисленные способы защиты от вредного воздействия электромагнитного излучения. Таким образом, можно сделать вывод, что рабочее место соответствует ГОСТ 12.1.006-84 ССБТ. Электромагнитные поля радиочастот. Общие требования безопасности .

4.1.2 Недостаточная освещенность рабочей зоны

Недостаток или неправильное распределение освещения снижает производительность труда, вызывает утомление глаз, провоцирует заболевания зрения и повышает уровень травматизма. Чтобы создать подходящие условия для студентов, необходимо выполнить требования к освещению помещений и рабочих мест.

В данном разделе должны быть решены следующие вопросы:

- выбор системы освещения;
- выбор источников света;
- выбор светильников и их расположение;
- выбор нормируемой освещённости;
- расчёт освещения методом светового потока.

Выбор системы освещения: в помещении, при написании магистерской диссертации использовалось общее освещение - искусственное.

Выбор источников света: в данном помещении искусственное освещение создается люминесцентными лампами типа ЛД.

При работе на ПЭВМ пользователь выполняет работу высокой точности (использование ЭВМ и одновременная работа с документами), при минимальном размере объекта различения 0,3-0,5 мм (толщина символа на экране), разряда работы

III, подразряда работы Г (экран - фон светлый/средний, символ – контраст объекта с фоном – средний/большой).

Согласно СНиП 52.13330.2016 нормируемая минимальная освещенность должна удовлетворять требованиям, указанным в таблице – 4.

Таблица – 4. Требования к освещению помещений жилых и общественных зданий при зрительной работе высокой точности

Характеристика зрительной работы	Наименьший или эквивалентный размер объекта различения, мм	Разряд зрительной работы	Подразряд зрительной работы	Контраст объекта с фоном	Характеристика фона	Искусственное освещение				Естественное освещение	
						Освещенность, лк		Сочетание нормируемых величин		КЕО e_H , %	
						При комбинированном освещении (всего) лк	При системе общего освещения, лк	показателя ослепленности и коэффициента пульсации		При верхнем или комбинированном освещении	При боковом освещении
								$P_{не}$, % более	K_p , % не более		
Высокой точности	От 0,3 до 0,5	III	г	Средний Большой	Светлый Средний	400	200	18	15	3,0	1,0

Выбор светильников: выбираем лампу дневного света ЛД-40, световой поток которой равен ФЛД = 2300 Лм.

Выбираем светильники с люминесцентными лампами типа ОДОР-2-40. Этот светильник имеет две лампы мощностью 40 Вт каждая, $l_{св}$ – длина светильника равна 1227 мм, ширина – 265 мм.

Выбор нормируемой освещенности и дальнейшие расчеты: расчёт общего равномерного искусственного освещения горизонтальной рабочей поверхности

выполняется методом коэффициента светового потока, учитывающим световой поток, отражённый от потолка и стен. Длина помещения $A = 6$ м, ширина $B = 5$ м, высота $H = 3,5$ м. Высота рабочей поверхности над полом $h_{\text{рп}} = 0,75$ м. Интегральным критерием оптимальности расположения светильников является величина λ , которая для люминесцентных светильников с защитной решёткой лежит в диапазоне 1,1–1,3.

Рассчитываем систему общего люминесцентного освещения:

Приняв $h_c = 0,7$, определяем расчетную высоту светильника над рабочей поверхностью:

$$h = H - h_c - h_{\text{рп}} = 3,5 - 0,7 - 0,75 = 2,05 \text{ м}$$

Расстояние между светильниками:

$$L = \lambda \cdot h = 1,1 \cdot 2,05 = 2,25 \text{ м}$$

Расстояние от крайнего ряда светильников до стены:

$$l = \frac{L}{3} = 0,75 \text{ м}$$

Определяем количество рядов светильников и количество светильников в ряду:

$$n_{\text{ряд}} = \frac{(B - \frac{2}{3}L)}{L} + 1 = \frac{(5 - \frac{2}{3} \cdot 2,25)}{2,25} + 1 \approx 3$$

$$n_{\text{св}} = \frac{(A - \frac{2}{3}L)}{l_{\text{св}} + 0,5} = \frac{(6 - \frac{2}{3} \cdot 2,25)}{1,23 + 0,5} \approx 3$$

Общее число светильников:

$$N = n_{\text{ряд}} \cdot n_{\text{св}} = 9$$

Учитывая, что в каждом светильнике установлено две лампы, общее число ламп в помещении $N = 18$.

Находим индекс освещенности помещения:

$$i = \frac{S}{h \cdot (A + B)} = \frac{30}{2,05 \cdot 11} = 1,33$$

Потребный световой поток лампы определяется по формуле:

$$\Phi = \frac{E_{\text{н}} \cdot S \cdot K_z \cdot Z}{N \cdot \eta}$$

где E_H – нормируемая минимальная освещённость по СНиП 52.13330.2016 лк;

K_Z – коэффициент запаса, учитывающий загрязнение светильника (источника света, светотехнической арматуры, стен и пр., т. е. отражающих поверхностей), наличие в атмосфере цеха дыма, пыли;

Z – коэффициент неравномерности освещения, отношение $\frac{E_{cp}}{E_{min}}$. Для люминесцентных ламп при расчётах берётся равным 1,1;

N – число ламп в помещении;

η – коэффициент использования светового потока.

Данное помещение относится к типу помещения с малым выделением пыли, в связи с этим $K_Z = 1,5$. Состояние потолка – свежепобеленный, поэтому значение коэффициента отражения потолка $R_n = 70\%$, состояние стен – побеленные бетонные стены, поэтому значение коэффициента отражения стен $R_c = 50\%$. Коэффициент использования светового потока, показывающий какая часть светового потока ламп попадает на рабочую поверхность, для светильников типа ОДОР с люминесцентными лампами при $R_n = 70\%$, $R_c = 50\%$ и индексе помещения $i = 1,3$ равен $\eta = 0,45$.

$$\Phi = \frac{E_H \cdot S \cdot K_Z \cdot Z}{N \cdot \eta} = \frac{200 \cdot 30 \cdot 1,5 \cdot 1,1}{18 \cdot 0,45} = 1222 \text{ Лм}$$

Для люминесцентных ламп с мощностью 40Вт и напряжением сети 220В, стандартный световой поток ЛД равен 2300 Лм. Делаем проверку выполнения условия:

$$-10\% \leq \frac{\Phi_{л.станд} - \Phi_{л.расч}}{\Phi_{л.станд}} \cdot 100\% \leq +20\%$$

Получаем:

$$\frac{2300 - 1222}{1222} \cdot 100\% = -8,8\%$$

$$-10\% \leq -8,8\% \leq +20\%$$

Также определим электрическую мощность осветительной установки:

$$P = 18 * 40 = 720 \text{ Вт}$$

Таким образом необходимый световой поток светильника не выходит за пределы требуемого диапазона.

Нервно – психические перегрузки

Нервно-психические перегрузки – совокупность таких сдвигов в психофизиологическом состоянии организма человека, которые развиваются после совершения работы и приводят к временному снижению эффективности труда.

К нервно – психическим перегрузкам согласно ГОСТ 12.0.003-2015 ССБТ «Опасные и вредные производственные факторы. Классификация» относятся [6]:

- Монотонность труда, вызывающая монотонию;
- Умственное перенапряжение, в том числе вызванное информационной нагрузкой;
- Перенапряжение анализаторов, в том числе вызванное информационной нагрузкой;
- Эмоциональные перегрузки.

Чтобы не перенапрягать человеческий организм, следует устанавливать регламентированные нормы труда и отдыха при работе за компьютером.

Так, например, чтобы снизить зрительное напряжение нужно соблюдать следующие рекомендации:

- Следует избегать большого контраста между яркостью экрана и окружающего пространства;
- Запрещается работа на компьютере в темном и полутемном пространстве;
- Минимальная диагональ для монитора персонального компьютера и ноутбука должна составлять не менее 39,6 см, планшета - 26,6 см. Использование мониторов на основе электронно-лучевых трубок в образовательных организациях не допускается [12].

Чтобы минимизировать последствия других нервно – психических перегрузок, согласно Трудовому кодексу Российской Федерации от 30.12.2001 N 197-ФЗ (ред. от 09.03.2021), необходимо кроме ежедневного отдыха и выходных, устраивать перерывы в течении рабочего дня [2].

4.1.3 Повышенное значение напряжения в электрической цепи, замыкание которой может пройти через тело человека

В зависимости от условий в помещении опасность поражения человека электрическим током увеличивается или уменьшается. Все помещения делятся на [15]:

- Помещения с повышенной опасностью;
- Особо опасные помещения;
- Помещения без повышенной опасности.

Помещение, в котором была создана магистерская диссертация, принадлежит к категории помещений без повышенной опасности по степени вероятности поражения электрическим током, так как характеризуется отсутствием признаков помещений повышенной и особой опасности (например, отсутствием сырости, высокой температуры воздуха, токопроводящей пыли) [15].

Для данной магистерской диссертации компьютер рассматривается как приемник электрической энергии, который в случае подключения к электрической сети, размещенной на территории помещения, становится частью электроустановки и является потребителем электрической энергии.

Вследствие этого к оборудованию предъявляются следующие требования:

- Наличие защитного заземления, зануления или отключения;
- Недоступность токоведущих частей для случайного прикосновения;

Перед началом работы следует убедиться в отсутствии свешивающихся со стола или висящих под столом проводов электропитания, в целостности вилки и провода электропитания, в отсутствии видимых повреждений аппаратуры и рабочей мебели, в отсутствии повреждений и наличии заземления.

Обоснование мероприятий по снижению уровней воздействия опасных и вредных факторов на исследователя

Основными профилактическими мероприятиями, по снижению уровней воздействия опасных и вредных факторов на студента являются:

- Не рекомендуется работать за компьютером более 6 часов за смену;
- Рекомендуется делать перерывы в работе за ПК продолжительностью 10-15 минут через каждые 45-60 минут работы;

– Во время регламентированных перерывов целесообразно выполнять комплексы упражнений и осуществлять проветривание помещения;

– Чтобы вычислительная техника соответствовала нормам, необходимо осуществлять производственный контроль используемой аппаратуры.

Рабочее место должно быть организовано в соответствии с требованиями стандартов, технических условий и (или) методических указаний по безопасности труда.

4.2 Экологическая безопасность

При написании магистерской диссертации были выявлены предполагаемые источники загрязнения окружающей среды, а именно воздействие на литосферу в результате образования таких отходов, как: бумажные черновики, использованные картриджи, люминесцентные лампы, компьютерное оборудование и предметы оргтехники. Все эти предметы должны быть правильно утилизированы в соответствии со своими техническими характеристиками.

В таблице 5 представлены перечисленные выше отходы и способы их утилизации.

Таблица – 5. Утилизация твердых отходов

Наименование отхода	Место захоронения, утилизация	Последствия попадания отходов в окружающую среду
Бумажные черновики	Бумага относится к вторичным материальным ресурсам. Может быть сдана на макулатуру, а затем быть использована при вторичном производстве бумаги. Класс отходов – 5 по ГОСТ 10700-97	При производстве бумаги добавляется хлорсодержащие отбеливатели. В результате разложения бумаги на свалке, выделяется опасный метан.
Картриджи (тяжелые металлы, пластик, производные этилена, полистирол и другие полимеры)	Разбираются на составляющие, далее детали сортируются в соответствии с материалом, из которого они изготовлены. Затем часть сырья	В естественных условиях разлагается несколько столетий, нанося поверхности планеты колоссальный ущерб. В использованном картридже

	перерабатывается, а остатки уничтожаются. Класс отходов – 4 по ГОСТ Р 56195-2014	остатки краски попадая в воздух могут вызвать у людей смертельно опасные заболевания.
Люминесцентные лампы (ртуть, стекло)	Сдаются в приемный пункт завода светотехники. Откуда часть отходов отправляется на вторичную переработку, а часть подлежит обязательному захоронению. Класс отходов – 1 по ГОСТ Р 52105-2003	Компоненты люминесцентных ламп проникая в почву, заражают ее и растения. Ртуть также имеет вредное воздействие и на животных, у которых с ее накоплением происходит угнетение жизненно важных функций.
Компьютерное оборудование, оргтехника (тяжелые металлы, пластмассы, стекло, провода, штекеры)	Происходит разборка техники и реализация партий лома. Более 90 % отправляется на вторичную переработку, и менее 10 % вывозятся на свалки. Класс отходов с 1 по 4 по ГОСТ Р 55102-2012	При неправильной утилизации тяжелые металлы отравляют окружающую среду. Компоненты техники разлагаются несколько столетий.

Переработку, обезвреживание и захоронение вышеперечисленных промышленных отходов производят на специальных перегонах, создаваемых в соответствии с требованиями СП 127.13330.2017 «Полигоны по обезвреживанию и захоронению токсичных промышленных отходов. [16] и ФЗ «Об отходах производства и потребления» от 24.06.1998 N 89-ФЗ [17].

Данный проект не оказывает негативного воздействия ни на гидросферу, ни на атмосферу, ни на литосферу все используемые отходы утилизируются согласно ГОСТ Р 55102-2012 НАЦИОНАЛЬНЫЙ СТАНДАРТ РОССИЙСКОЙ ФЕДЕРАЦИИ. Ресурсосбережение. Обращение с отходами. Руководство по безопасному сбору, хранению, транспортированию и разборке отработавшего электротехнического и электронного оборудования, за исключением ртутьсодержащих устройств и приборов [20].

4.3 Безопасность в чрезвычайных ситуациях

Чрезвычайными ситуациями в подобных помещениях могут быть

пожары. Основы пожарной безопасности определены по ГОСТ 12.1.004-91 [17] и ГОСТ 12.1.010-76 [18].

Все производства по пожарной опасности подразделяются на 5 категорий: А, Б, В, Г, Д. Аудитория, в которой будет выполняться работа, относится к категории В.

При возникновении пожара должна сработать система пожаротушения, издав предупредительные сигналы, и передав на пункт пожарной станции сигнал о ЧС, в случае если система не сработала, по каким-либо причинам, необходимо самостоятельно произвести вызов пожарной службы по телефону 101, сообщить место возникновения ЧС и направиться к аварийному выходу.

Причинами пожара могут быть:

- токи короткого замыкания;
- электрические перегрузки;
- выделение тепла, искрение в местах плохих контактов при соединении проводов;
- курение в неположенных местах.

Тушение горящего электрооборудования под напряжением должно осуществляться имеющимися огнетушителями ОУ-5. Чтобы предотвратить пожар в аудитории, необходимо:

- содержать помещение в чистоте, убирать своевременно мусор. По окончании работы поводится влажная уборка всех помещений;
- работа должна проводиться только при исправном электрооборудовании;
- на видном месте должен быть вывешен план эвакуации из помещения с указанием оборудования, которое нужно эвакуировать в первую очередь;
- уходящий из помещения последним должен проверить выключены ли нагревательные приборы, электроприборы и т.д. и отключение силовой и осветительной электрической сети.

Также необходимо соблюдение организационных мероприятий:

- правильная эксплуатация приборов, установок;
- правильное содержание помещения;
- противопожарный инструктаж сотрудников аудитории;
- издание приказов по вопросам усиления ПБ;
- организация добровольных пожарных дружин, пожарно-технических комиссий;
- наличие наглядных пособий и т.п.

В случаях, когда не удастся ликвидировать пожар самостоятельно, необходимо эвакуироваться вслед за сотрудниками по плану эвакуации и ждать приезда специалистов, пожарников. При возникновении пожара должна сработать система пожаротушения, издав предупредительные сигналы, и передав на пункт пожарной станции сигнал о ЧС, в случае если система не сработала, по каким-либо причинам, необходимо самостоятельно произвести вызов пожарной службы по телефону 101, сообщить место возникновения ЧС и ожидать приезда специалистов.

4.4 Выводы по разделу «Социальная безопасность»

Таким образом можно сделать вывод по всему разделу «Социальная ответственность», что на рабочем месте показатели микроклимата, освещенности и электромагнитных излучений находятся в норме, что говорит о безопасности для человека. Анализ выявленных опасных факторов рабочего помещения показал, что электробезопасность, пожаробезопасность и экологическая безопасность находятся под контролем, и все необходимые меры для обеспечения безопасности принимаются.

ФИНАНСОВЫЙ МЕНЕДЖМЕНТ, РЕСУРСОЭФФЕКТИВНОСТЬ И РЕСУРСОСБЕРЕЖЕНИЕ

В научно-исследовательских проектах важную роль играет его коммерциализация. Разработчикам и исследователям следует учитывать такие факторы как его экономическая эффективность, конкурентоспособность и экологичность, так как спонсоры и доноры обращают на это особое внимание. Рентабельность проекта зависит от её себестоимости, времени на реализацию и спрос.

В данном разделе рассматривается раздел коммерческая выгода НИОКР и расчет затрат, необходимых для её проведения.

Предпроектный анализ

Потенциальные потребители результатов исследования

Разработчик заинтересован в монетизации его проекта, причём проект должен обеспечить прибыль в достаточном объеме. Поэтому перед разработкой необходимо чёткое представление о том, кто является конечным потребителем, т.е. целевой рынок и сегментировать его.

Целевой рынок – сегменты рынка, на котором будет продаваться в будущем разработка. Сегмент рынка – это особым образом выделенная часть рынка, группы потребителей, обладающих определенными общими признаками. Сегментирование – это разделение покупателей на однородные группы, для каждой из которых может потребоваться определенный товар или услуга [35].

В ходе данной работы был разработан чат-бот, который позволяет автоматизировать большинство процессов для сотрудников предприятий, что позволяет существенно сократить время при выполнении повседневных задач, таких как электронный документооборот, обучение сотрудников, отправка писем с электронной почты и так далее.

Целевым рынком чат-ботов являются коммерческие организации. Критериями сегментирования в нашем случае выступают компании и требуемый для них функционал. Результат сегментирования представлен на рис. 14.

		По требуемому функционалу		
		Чат-бот для поиска информации и обработки простых запросов на естественном языке	Чат-бот с расширенным функционалом (отправка сообщений по электронной почте, заполнение документов и электронный документооборот)	Чат-бот с расширенными возможностями и гибкой настройкой всех функций.
Размер компании	Крупные			
	Средние			
	Мелкие			

Рисунок 14 – Карта сегментирования рынка чат-ботов

Анализ конкурентных технических решений с позиции ресурсоэффективности и ресурсосбережения

Нужно провести анализ существующих конкурирующих разработок на рынке. Так как рынки постоянно развиваются этот анализ должен быть систематическим. Анализ подобных разработок позволяет более эффективно конкурировать с оппонентами путем внесения корректировок в проект. Важна реалистичная оценка конкурентов. Для этого нужно использовать всю информацию об их разработках такие как:

- Технические характеристики разработки
- Конкурентоспособность
- Завершенность проекта

- Бюджет
- Уровень проникновения на рынок
- Финансовое положение

Анализ конкурентных технических решений с позиции ресурсоэффективности и ресурсосбережения позволяет провести оценку сравнительной эффективности научной разработки и определить направления для ее будущего повышения. Анализ проведен в таблице 6, где конкурент 1 – это компания «Singularika» [36], и конкурент 2 – компания «Крок» [37].

Анализ конкурентных технических решений определяется по формуле:

$$K_i = \sum_{i=1}^n B_i B_i \quad 6)$$

где K – конкурентоспособность разработки или конкурента; B_i – вес i -го показателя (в долях единицы); B_i – балл i -го показателя.

Таблица 6 – Оценочная карта для сравнения конкурентных технических решений

Критерии оценки	Вес	Баллы			Конкурентоспособность		
		Б _ф	Б _{к1}	Б _{к2}	К _ф	К _{к1}	К _{к2}
Технические критерии оценки ресурсоэффективности							
1. Способствует увеличению скорости выполнения рутинных задач	0,15	5	4	4	0,75	0,6	0,6
2. Удобство в эксплуатации (соответствует требованиям потребителей, все функции внутри одного приложения)	0,13	5	5	5	0,65	0,65	0,65
3. Безопасность	0,10	4	4	4	0,4	0,4	0,4
4. Надежность	0,10	4	3	3	0,4	0,3	0,3
5. Простота эксплуатации (понятный интерфейс и функции)	0,09	5	4	4	0,45	0,36	0,36
Экономические критерии оценки эффективности							
6. Цена	0,10	5	3	4	0,5	0,3	0,4
7. Конкурентоспособность продукта	0,09	4	4	4	0,36	0,36	0,36
8. Предполагаемый срок эксплуатации	0,09	5	5	5	0,45	0,45	0,45
9. Срок выхода на рынок	0,08	4	5	5	0,32	0,4	0,4
10. Послепродажное обслуживание	0,07	5	3	3	0,35	0,21	0,21
Итого	1	46	40	41	4,63	4,03	4,13

Таким образом, конкурентоспособность нашей разработки составила 4,63, в то время как у «Singularika» и «Крок» этот показатель составил 4,03 и 4,13 соответственно. Результаты показывают, что данная разработка является конкурентоспособной и имеет преимущества по некоторым критериям.

SWOT-анализ

SWOT-анализ – это комплексный стратегический анализ научно-исследовательского проекта, которая применяется для исследования внутренних и внешних среды проекта. SWOT – это английская аббревиатура, которую можно расшифровать как Strengths (сильные стороны), Weaknesses (слабые стороны), Opportunities (возможности) и Threats (угрозы).

Анализ проводится в несколько этапов. На первом этапе нужно определить эти сильные и слабые стороны, возможности и угрозы относительно нашего проекта.

На втором этапе нужно создать несколько интерактивных матриц и посмотреть различные взаимосвязи на шаге 1. В интерактивной матрице ставиться знак «+», если одни характеристики сильно соответствуют другим (например, соответствие сильных сторон возможностям), знак «-», если эта связь слабая и «0», если имеются сомнения. Интерактивные матрицы приведены в таблицах 7-10.

Третий этап – это делать логические выводы исходя из интерактивных таблиц. Результаты приведены в таблице 11.

Таблица 7 – Интерактивная матрица «Сильные стороны и возможности проекта»

Таблица 8 – Интерактивная таблица «Слабые стороны и возможности»

		Сильные стороны		
		C1	C2	C3
Возможности	B1	+	+	+
	B2	+	0	+
	B3	+	+	-

		Слабые стороны		
		Сл1	Сл2	Сл3
Возможности	B1	+	+	+
	B2	-	0	+
	B3	+	-	+

Таблица 9 – Интерактивная матрица «Сильные стороны и угрозы»

		Сильные стороны		
		C1	C2	C3
Угрозы	У1	0	0	0
	У2	+	-	+
	У3	+	-	-
	У4	-	+	-

Таблица 10 – Интерактивная таблица «Слабые стороны и угрозы»

		Слабые стороны		
		C1	C2	C3
Угрозы	У1	0	+	0
	У2	+	+	+
	У3	+	+	+
	У4	+	+	+

Таблица 11 – SWOT-анализ, первый этап.

	<p>Сильные стороны (С):</p> <ol style="list-style-type: none"> Опытный научный руководитель; Продукт, реализованный на языке Python и бесплатных библиотеках машинного обучения; Чат-бот с LSTM (Longshort-termmemory – долгая краткосрочная память); 	<p>Слабые стороны (Сл):</p> <ol style="list-style-type: none"> Малый опыт работы разработчика на реальных проектах; Трудоёмкий процесс разработки и тестирования; Большие затраты времени на вычисления и обучение модели;
<p>Возможности (В):</p> <ol style="list-style-type: none"> Актуальность разработки; Ориентация на крупных потенциальных покупателей; Относительная легкость внедрения продукта; 	<p>V1C1C2C3 – позволят установить относительно невысокую цену на актуальный продукт;</p> <p>V2C1C3 – помогут удовлетворить потребности крупных покупателей.</p> <p>V3C1C2 – легко внедряемое современное решение в корпоративные сети.</p>	<p>V1Сл1Сл2Сл3 – разработка ведется на достаточно известном языке программирования Python, то на большинство вопросов уже имеются ответы в документациях библиотек, а также примеры использования.</p> <p>V2Сл3 – обычно крупные компании имеют большие сервера, которые смогут быстрее справляться с большими массивами данных.</p>
<p>Угрозы (У):</p> <ol style="list-style-type: none"> Возможный экономический кризис после пандемии COVID19; Дополнительные государственные требования при получении лицензии на продукт; Возможная уязвимость ПО 	<p>У2С1С3 – опытный научный руководитель сможет помочь в продвижении продукта.</p> <p>У3С1 – программное обеспечение может быть проверено на наличие уязвимостей научным руководителем.</p> <p>У4С2 – так как используется инструменты с открытым исходным кодом, то на большинство вопросов, возникающих в процессе разработки, можно найти ответы в сети интернет.</p>	<p>У1Сл2 – реализовать проект в условиях пандемии ещё сложнее.</p> <p>У2Сл1Сл2Сл3 – наличие опыта работы в реальных проектах снизило бы количество времени затрачиваемую на получение лицензии на конечный продукт.</p> <p>У3Сл1Сл2Сл3 – перечисленные сложности могут способствовать появлению уязвимостей в ПО.</p> <p>У4Сл1Сл2Сл3 – вышеуказанные сложности могут способствовать изменению поведения данных.</p>

4. Измениться поведение ПО при использовании больших массивов данных		
--	--	--

– В рамках проведения SWOT-анализа были изучены сильные и слабые стороны, а также возможности и возможные угрозы, которые необходимо учесть при реализации проекта.

Оценка готовности проекта к коммерциализации

Независимо от того на какой стадии находится программное обеспечение (научная разработка) важно оценить готовность его к коммерциализации и выяснить уровень собственных знаний для её проведения (или завершения). На таблице 12 приведены оценки степени готовности проекта к коммерциализации, где оценка проработанности трактуется следующим образом:

- 5 – имеется положительное заключение независимого эксперта;
- 4 – выполнено качественно;
- 3 – выполнено, но под сомнением;
- 2 – проработано слабо;
- 1 – не проработано.

В таблице также приведены оценки уровня знаний у разработчика, где баллы трактуются так:

- 5 – знаком с теорией, выполняет, может консультировать;
- 4 – знаком с теорией и самостоятельно выполняет;
- 3 – знаком с теорией и практическими примерами применения;
- 2 – знаком с теорией;
- 1 – не знаком или мало знаком.

Оценка готовности научного проекта к коммерциализации (или уровень знаний) определяется по формуле:

$$B_{\text{сум}} = \sum B_i \quad (7)$$

где $B_{\text{сум}}$ – это суммарное количество баллов по каждому направлению; B_i – балл по каждому показателю.

Таблица 12 – Оценки степени готовности научного проекта к коммерциализации

№ п/п	Наименование	Степень проработанности научного проекта	Уровень имеющихся знаний у разработчика
1	Определен имеющийся научно-технический задел	4	4
2	Определены перспективные направления коммерциализации научно-технического задела	5	5
3	Определены отрасли и технологии (товары, услуги) для предложения на рынке	5	5
4	Определена товарная форма научно-технического задела для представления на рынок	2	2
5	Определены авторы и осуществлена охрана их прав	3	3
6	Проведена оценка стоимости интеллектуальной собственности	5	5
7	Проведены маркетинговые исследования рынков сбыта	2	2
8	Разработан бизнес-план коммерциализации научной разработки	1	1
9	Определены пути продвижения научной разработки на рынок	4	4
10	Разработана стратегия (форма) реализации научной разработки	3	3
11	Проработаны вопросы международного сотрудничества и выхода на зарубежный рынок	2	3
12	Проработаны вопросы использования услуг инфраструктуры поддержки, получения льгот	4	4
13	Проработаны вопросы финансирования коммерциализации научной разработки	4	4
14	Имеется команда для коммерциализации научной разработки	4	4
15	Проработан механизм реализации научного проекта	4	4
Итого		52	54

Значение $B_{\text{сум}}$ позволяет говорить о том, на сколько готовы проект и разработчики к коммерциализации. Так как их значения выше среднего можно делать вывод о том, что у проекта перспективы выше среднего.

Методы коммерциализации результатов научно-технического исследования

При коммерциализации научно-технических разработок продавец (а это, как правило, владелец соответствующих объектов интеллектуальной собственности), преследует вполне определенную цель, которая во многом зависит от того, куда в последующем он намерен направить (использовать, вложить) полученный коммерческий эффект. Это может быть получение средств для продолжения своих научных исследований и разработок (получение финансирования, оборудования, уникальных материалов, других научно-технических разработок и т.д.), одноразовое получение финансовых ресурсов для каких-либо целей или для накопления, обеспечение постоянного притока финансовых средств, а также их различные сочетания.

Правильный выбор метода коммерциализации может существенно сократить время на продвижение товара. Для данного проекта оптимальным решением будет инжиниринг. Инжиниринг – это 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 [35].

Инициация проекта

На этом этапе принято выполнить определенные работы для успешного запуска проекта. Здесь следует определить цели и результаты проекта, определить рабочую группу, определить ограничения и допущения. Вся эта информация заносится в документ, называемый уставом проекта.

Уставом проекта называется документ, который определяет бизнес-потребности и текущее понимание потребностей заказчика, а также новый продукт, услугу или результат, который планируется создать.

Цели и результат проекта. Здесь необходимо определить цели и результаты проекта, а также, определяются внутренние и внешние заинтересованные стороны проекта, которые в конечном итоге повлияют на итоговый результат проекта. Информацию по заинтересованным сторонам проекта приведены в таблице 13, а цели проекта, ожидаемые результаты, критерий приемки и требования к результату проекта на таблице 14.

Таблица 13 – Заинтересованные стороны проекта

Заинтересованные стороны проекта	Ожидания заинтересованных сторон
Крупные предприятия, которые обладают корпоративными сетями и манипулируют большими массивами данных.	Внедрение чат-бота за короткие сроки, автоматизация рутинных задач.

Таблица 14 – Цели и результаты проекта

Цель проекта:	Разработка чат-бота с LSTM с обработкой естественного языка встраиваемый в корпоративные сети предприятий.
Ожидаемый результат:	Разработанный для внедрения в корпоративные сети предприятий.
Критерии приемки результата проекта:	- Точность обработки запросов на естественном языке свыше 85%; - Функции взаимодействия с пользователями, в том числе: отправка писем по электронной почте, поиск в интернете и другое.
Требования к результату проекта:	Требование:
	1. Отсутствие угрозы утечки информации корпоративных пользователей;
	2. Необходимое количество времени для внедрения в корпоративные сети;
	3. Надежность ПО (отказоустойчивость, не конфликтность с другими приложениями).

Организационная структура проекта. На данном этапе необходимо определить, кто будет входить в рабочую группу данного проекта, определить роль каждого участника, а также прописать функции, выполняемые каждым из них и их трудозатраты в проекте. Эта функция представлена в таблице 15.

Таблица 15 – Рабочая группа проекта

ФИО, основное место работы, должность	Роль в проекте	Функции в проекте	Трудозатраты, час.
Семенов М.Е. доцент, к.ф.м.н, отделение экспериментальной физики ТПУ	Руководитель проекта	Координатор	28
Курбонов К.С, магистрант	Исполнитель по проекту	Разработчик	546

В ходе реализации научного проекта, помимо магистранта задействован руководитель проекта:

Руководитель проекта – отвечает за реализацию проекта в пределах заданных ограничений по ресурсам, координирует деятельность участников проекта. В рамках данного проекта эту роль выполняет руководитель магистерской диссертации.

Исполнитель по проекту – специалист, выполняющий отдельные работы по проекту. В рамках этого проекта исполнителем является магистрант.

Ограничения и допущения проекта. Ограничения проекта – это факторы, которые ограничивают действия членов команды, а также границы проекта, за рамки которых выходить нельзя. Эти ограничения приведены в таблице 16.

Таблица 16 – Ограничения проекта

Фактор	Ограничения/допущения
Бюджет проекта	109 051,36 руб.
Источник финансирования	НИИ ТПУ
Сроки проекта	27.01-31.05.2021
Дата утверждения плана управления проектом	27.01.2021
Дата завершения проекта	31.05.2021
Прочие ограничения и допущения	Ограниченные вычислительные мощности для проведения расчетов

Планирование управления научно-техническим проектом

Группа процессов планирования состоит из процессов, осуществляемых для определения общего содержания работ, уточнения целей и разработки последовательности действий, требуемых для достижения данных целей [35].

План управления должен состоять из следующих элементов:

- Иерархическая структура проекта
- План проекта
- Бюджет проекта
- Организационная структура проекта
- План управления коммуникациями проекта
- Реестр рисков проекта

1.1.2 Иерархическая структура проекта

В Иерархической структуре проекта структурируется и определяется все содержание проекта. На рис. 1 построена иерархическая структура научно-исследовательского проекта «Разработка чат-бота с обработкой естественного языка».

1.1.3 План проекта

В рамках планирования проекта нужно построить календарный и сетевой графики проекта.

Линейный график представлена в виде таблицы (таблица 17).

Диаграмма Ганта – это, по сути, гистограмма, которая визуализирует календарный план проекта, на котором работы по теме отображаются в виде шкалы времени. Диаграмма проекта построена на рис. 16.

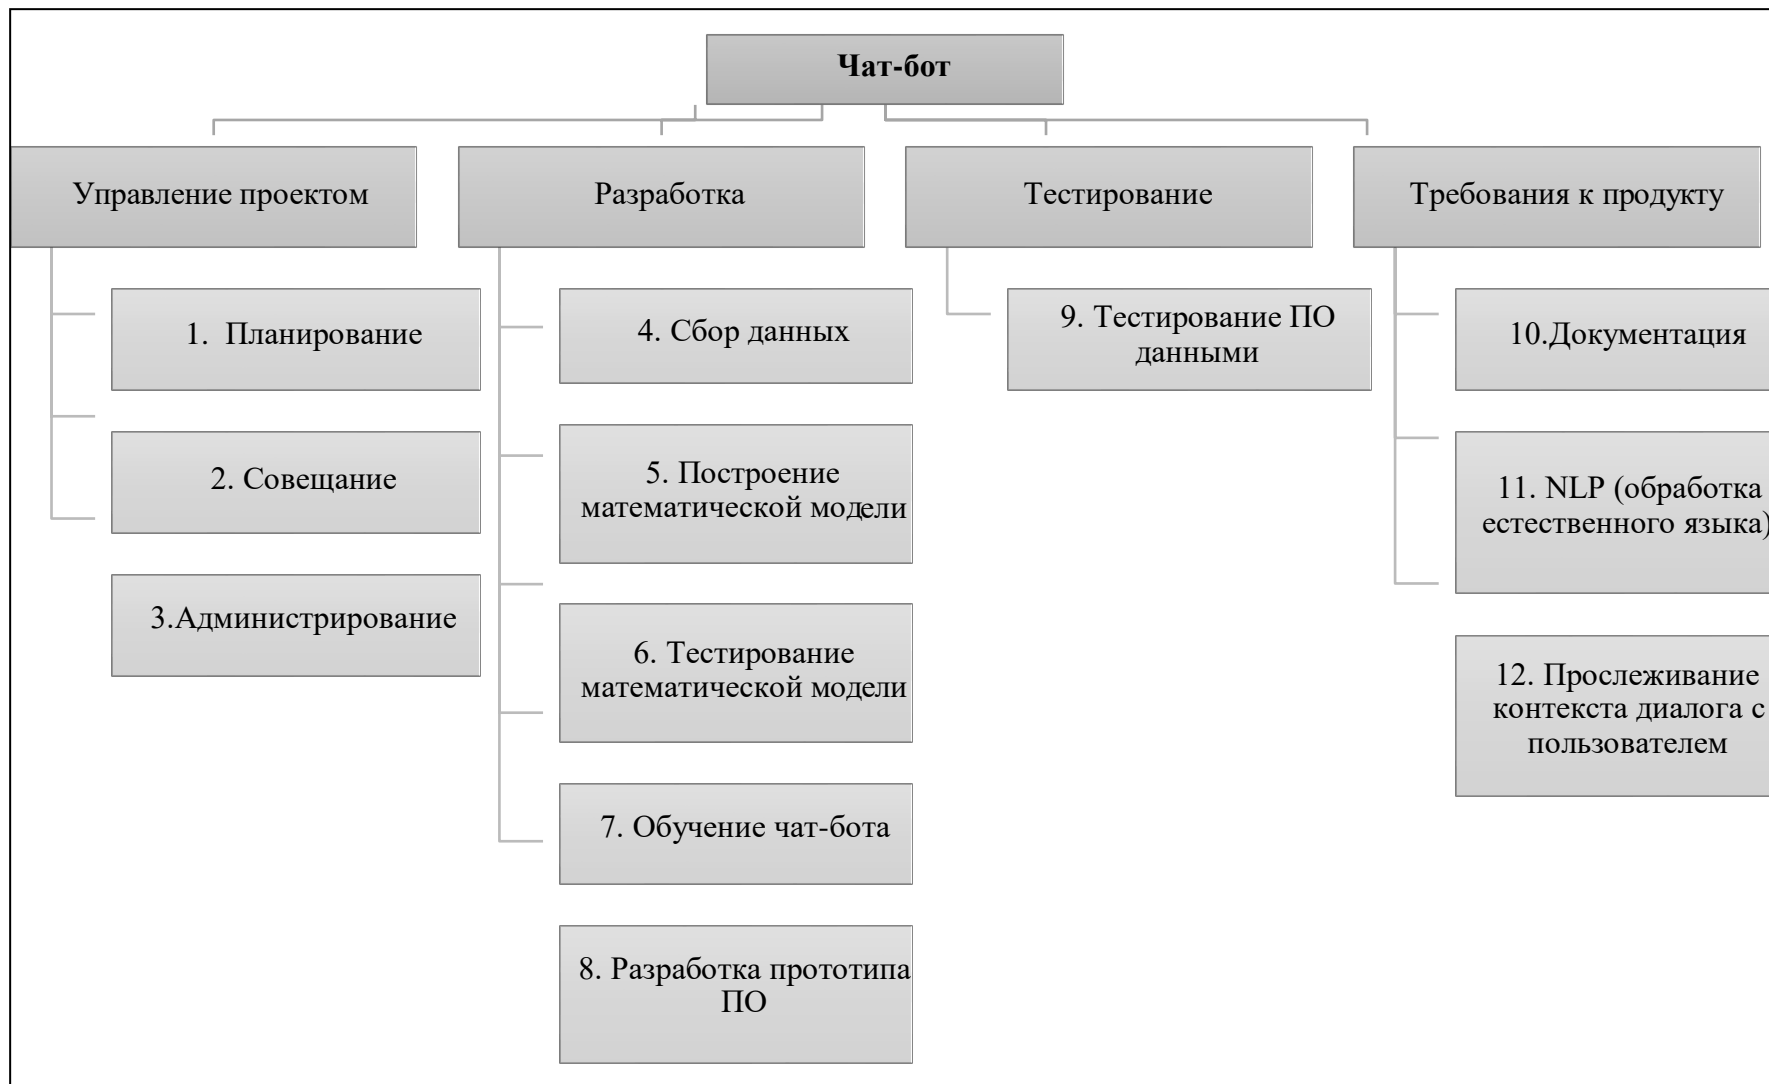


Рисунок15 – Иерархическая структура «Разработка чат-бота с обработкой естественного языка»

Таблица 17 – Календарный план проекта

Код работы (из ИСР)	Название	Длительность, дни	Дата начала работ	Дата окончания работ	Состав участников (ФИО ответственных исполнителей)
1	Планирование	5	27.01.2021	31.01.2021	Семенов М.Е. Курбонов К.С
2	Совещание	1	3.02.2021	3.02.2021	Семенов М.Е. Курбонов К.С
4	Сбор данных	14	4.02.2021	21.02.2021	Курбонов К.С
5	Построение математической модели	14	24.02.2021	12.03.2021	Курбонов К.С
6	Тестирование математической модели	7	13.03.2021	23.03.2021	Курбонов К.С
7	Обучение чат-бота	21	24.03.2021	20.04.2021	Курбонов К.С
8	Разработка прототипа ПО	5	21.04.2021	27.04.2021	Курбонов К.С
9	Тестирование ПО с тестовыми данными	5	28.04.2021	04.05.2021	Семенов М.Е. Курбонов К.С
10	Документирование	29	21.04.2021	29.05.2021	Курбонов К.С
Итого:		90	27.01.2021	29.05.2021	




Рисунок 16 – Диаграмма Ганта

Бюджет научного исследования

При планировании бюджета необходимо указать полные и достоверные данные о планируемых расходах, необходимого для выполнения проекта.

Специальное оборудование для научных(экспериментальных)работ

В данную статью включают все затраты, связанные с приобретением специального оборудования (приборов, контрольно-измерительной аппаратуры, стендов, устройств и механизмов), необходимого для проведения работ по конкретной теме. Определение стоимости спецоборудования производится по действующим прейскурантам, а в ряде случаев по договорной цене. Расчет затрат на спецоборудование приведен в таблице 18.

Таблица 18– Расчет затрат по статье «Спецоборудование для научных работ»

№ п/п	Наименование оборудования	Кол-во единиц оборудования	Цена единицы оборудования, тыс.руб.	Общая стоимость оборудования, тыс.руб.
1.	Ноутбук Lenova G570	1	32500	32500

Основнаязаработная плата

Статья включает основную заработную плату работников, непосредственно занятых выполнением проекта, (включая премии, доплаты) и дополнительную заработную плату.

$$C_{зп} = Z_{осн} + Z_{доп}, \quad (8)$$

где $Z_{осн}$ – основная заработная плата; $Z_{доп}$ – дополнительная заработная плата. Основная заработная плата ($Z_{осн}$) руководителя от университета:

$$Z_{осн} = Z_{дн} * T_{раб}, \quad (9)$$

где $Z_{осн}$ – основная заработная плата работника; $T_{раб}$ – продолжительность работ, выполняемых научно-техническим работником, раб. дн.; $Z_{дн}$ – среднедневная заработная плата работника, руб.

Средняя заработная плата рассчитывается по формуле:

$$Z_{\text{дн}} = \frac{Z_{\text{м}} * M}{F_{\text{д}}}, \quad (10)$$

где $Z_{\text{м}}$ – месячный должностной оклад работника, руб.; M – количество месяцев работы без отпуска в течении года: при отпуске 48раб. дня за полгода $M = 10,4$ месяца, 6-дневная неделя; $F_{\text{д}}$ – действительный годовой фонд рабочего времени научно-технического персонала, раб. дн.

Месячный должностной оклад работника:

$$Z_{\text{м}} = Z_{\text{ТС}} * (1 + k_{\text{пр}} + k_{\text{д}}) * k_{\text{р}}, \quad (11)$$

где $Z_{\text{ТС}}$ – заработная плата по тарифной ставке, руб.; $k_{\text{пр}}$ – премиальный коэффициент, равный 0,3 (т.е. 30% от $Z_{\text{ТС}}$); $k_{\text{д}}$ – 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: 15-20% от $Z_{\text{ТС}}$); $k_{\text{р}}$ – районный коэффициент, равный 1,3 (для Томска).

Таблица 19 – Баланс рабочего времени

Показатели рабочего времени	Руководитель проекта	Исполнитель по проекту
Календарное число дней	365	365
Количество нерабочих дней	52	52
– выходные дни	14	14
– праздничные дни		
Потери рабочего времени	48	48
– отпуск		
Действительный годовой фонд рабочего	251	251

Месячный должностной оклад работника:

$$Z_{\text{м}} = Z_{\text{б}} * k_{\text{р}}, \quad (12)$$

где $Z_{\text{б}}$ – базовый оклад, руб.; $k_{\text{р}}$ – районный коэффициент, равный 1,3 (для Томска)

Таблица 20 – Расчет основной заработной платы

Исполнители	З _б , руб.	k _p	З _м ,руб.	З _{дн} , руб.	T _p раб. дн.	З _{осн} , руб.
Руководитель проекта	33664,00	1,3	43763,20	1813,30	11	19946,30
Исполнитель по проекту	1988,00	1,3	2584,40	108,08	90	9727,20

Дополнительная заработная плата

Дополнительная заработная плата включает оплату за непроработанное время (очередной и учебный отпуск, выполнение государственных обязанностей, выплата вознаграждений за выслугу лет и т.п.) и рассчитывается исходя из среднего значения в 10-12% от основной заработной платы, работников, непосредственно участвующих в выполнении темы:

$$Z_{\text{доп}} = K_{\text{доп}} \cdot Z_{\text{осн}}, \quad (13)$$

где $Z_{\text{доп}}$ – дополнительная заработная плата, руб.; $K_{\text{доп}}$ – коэффициент дополнительной зарплаты; $Z_{\text{осн}}$ – основная заработная плата, руб.

Таблица 21– Заработная плата исполнителей НИОКР

Заработная плата	Руководитель проекта	Исполнитель по проекту
Основная заработная плата	19946,30	9727,20
Дополнительная заработная плата (10%)	1994,63	972,72
Итого по статье С _{зп}	21940,93	9699,92

Отчисления на социальные нужды

Статья включает в себя отчисления во внебюджетные фонды.

$$C_{\text{внеб}} = k_{\text{внеб}} \cdot (Z_{\text{осн}} + Z_{\text{доп}}), \quad (14)$$

где $k_{\text{внеб}}$ – коэффициент отчислений во внебюджетные фонды (пенсионный фонд, фонд обязательного медицинского страхования и прочее).

Величина отчислений согласно постановлению Правительства РФ от 06.11.2019 №1407 [38] составляет: взносы на ОПС 22%, взносы на ОМС 5,1% и взносы на ВНиМ 2,9% итого 30%.

Таблица 22 – Отчисления во внебюджетные фонды

	Руководитель проекта	Исполнитель по проекту
Зарплата	21940,93	10699,92
Отчисления во внебюджетные фонды	6582,28	2209,98

Прочие прямые расходы

Ноутбук потребляет 0,15 кВт/ч. В Томске 1кВт/ч стоит 3,5 рублей. На работу за компьютером было затрачено 520 часов, что означает стоимость потраченной электроэнергии $0,15 \cdot 520 \cdot 3,5 = 273$ руб.

Накладные расходы

В данную статью входят расходы на содержание аппарата управления и общехозяйственных (общеуниверситетских) служб, которые в равной степени относятся ко всем выполняемым НИОКР. По этой статье учитываются оплата труда административно-управленческого персонала, содержание зданий, оргтехники и хозяйственного инвентаря, амортизация имущества, расходы по охране труда и подготовке кадров.

Накладные расходы лаборатории 10 корпуса НИ ТПУ составляют 80- 90% от суммы основной и дополнительной заработной платы, работников, непосредственно участвующих в выполнении темы. Расчет накладных расходов ведется по следующей формуле:

$$C_{\text{внеб}} = k_{\text{накл}} \cdot (Z_{\text{осн}} + Z_{\text{доп}}), \quad (15)$$

где $k_{\text{накл}}$ – коэффициент накладных расходов. $S_{\text{накл}} = 80\% \cdot S_{\text{зп}} = 26\,112,68$.

На основании сделанных расчётов можно посчитать плановую себестоимость НИР по форме, приведенной в таблице 23.

Таблица 23 – Группировка затрат по статьям

Вид работ	Статьи						
	Специальное оборудование для научных (экспериментальных) работ	Основная заработная плата	Дополнительная заработная плата	Отчисления на социальные нужды	Прочие прямые расходы	Накладные расходы	Итого плановая себестоимость
Создание и обучение чат-бота на базе математической модели	32500	29673,50	10699,92	9792,26	273	26112,68	109051,36

1.1.4 План управления коммуникациями проектами

План управления коммуникациями отражает требования к коммуникациям со стороны участников проекта. Управление коммуникациями нашего проекта приведен в таблице 24.

Таблица 24– План управления проектами

Какая информация передается	Кто передает информацию	Кому передается информация	Когда передает информацию
Обмен информацией о текущем состоянии проекта	Исполнитель проекта	Руководителю проекта	Еженедельно
Документы и информация по проекту	Исполнитель проекта	Руководитель проекта	Ежемесячно
О выполнении контрольной точки	Исполнитель проекта	Руководитель проекта	Не позже дня контрольного события по плану управления

1.1.5 Реестр рисков проекта

Идентифицированные риски проекта — это возможные неопределенные события, которые могут возникнуть в проекте и могут повлечь за собой нежелательные эффекты.

Таблица 25 – Реестр рисков

Риск	Потенциальное воздействие	Вероятность наступления (1-5)	Влияние риска (1-5)	Уровень риска*	Способы смягчения	Условия наступления
Отсутствие спроса со стороны ключевых потребителей для приобретения продукта	Отсутствие продаж	2	4	Средний	Разработка политики продвижения	Продукт не вызывает интерес, финансовый кризис
Технологические риски, связанные с использованием неизвестных ОС на серверах заказчика	Проблемы с внедрением готовой программы в корпоративные сети	1	3	Низкий	Изучить потенциальных клиентов	Переход на отечественное ПО, оборонное предприятие
Конкуренция на рынке выше ожидаемого	Снижения спроса на продукт	2	4	Средний	Изучение альтернативных технологий для снижения стоимости продукта	Цена, Выход нового продукта на рынок

* Уровень риска может быть: высокий, средний или низкий в зависимости от вероятности наступления и степени влияния риска.

1.2 Определение ресурсной (ресурсосберегающей), финансовой, бюджетной, социальной и экономической эффективности исследования

1.2.1 Оценка абсолютной эффективности исследования

В основе проектного подхода к инвестиционной деятельности предприятия лежит принцип денежных потоков (cashflow). 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 (NPV) – это показатель экономической эффективности инвестиционного проекта, который рассчитывается путём дисконтирования (приведения к текущей стоимости, т.е. на момент инвестирования) ожидаемых денежных потоков (как доходов, так и расходов).
- Расчёт NPV осуществляется по следующей формуле:

$$NPV = \sum_{t=1}^n \frac{ЧДП_{опt}}{(1+i)^t} - I_0, \quad (16)$$

где: ЧДП_{опt} – чистые денежные поступления от операционной деятельности;

I_0 – разовые инвестиции, осуществляемые в нулевом году;

t – номер шага расчета ($t = 0, 1, 2 \dots n$)

n – горизонт расчета;

i – ставка дисконтирования (желаемый уровень доходности инвестируемых средств).

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

Расчет чистой текущей стоимости представлен в таблице 26. При расчете рентабельность проекта составляла 20 %, амортизационные отчисления 10 %. Бюджет проекта = 109052 руб.

Коэффициент дисконтирования рассчитан по формуле:

$$КД = \frac{1}{(1+i)^t}, \quad (17)$$

где: i – ставка дисконтирования, 20 %;

t – шаг расчета.

Таким образом, чистая текущая стоимость по проекту в целом составляет 109194,26 рублей, что позволяет судить о его эффективности

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. Индекс доходности рассчитывается по формуле:

$$PI = \sum_{t=1}^n \frac{ЧДП_t}{(1+i)^t} / I_0, \quad (18)$$

где: ЧДП - чистый денежный поток, млн. руб.;

I_0 – начальный инвестиционный капитал, млн. руб.

Таблица 26 – Расчет чистой текущей стоимости по проекту в целом

№	Наименование показателей	Шаг расчета				
		0	1	2	3	4
1	Выручка от реализации, руб.	0	130863	130863	130863	130863
2	Итого приток, руб.	0	130863	130863	130863	130863
3	Инвестиционные издержки, руб.	-109052	0	0	0	0
4	Операционные затраты, руб.	0	0	0	0	0
5	Налогооблагаемая прибыль	0	130863	130863	130863	130863
6	Налоги 20 %, руб.	0	26172,60	26172,60	26172,60	26172,60
7	Итого отток, руб.	-109052	26172,60	26172,60	26172,60	26172,60
8	Чистая прибыль, руб.	0	104690,40	104690,40	104690,40	104690,40
9	Чистый денежный поток (ЧДП), руб.	-109052	115595,60	115595,60	115595,60	115595,60
10	Коэффициент дисконтирования (КД)	1	0,833333	0,694444	0,578704	0,482253
11	Чистый дисконтированный доход (ЧДД), руб.	-109052	96329,63	80274,67	66895,64	55746,32
12	Σ ЧДД		299246,26			
12	Итого NPV, руб.		109194,26			

$$PI = \frac{299246,26}{109052} = 2,744$$

Таким образом $PI > 1$, то проект является эффективным.

Значение ставки, при которой обращается в нуль, носит название «внутренней ставки доходности» или IRR. 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 $=0$. 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.

$$\sum_{t=1}^n \frac{ЧДП_{опt}}{(1 + IRR)^t} = \sum_{t=0}^n \frac{I_t}{(1 + IRR)^t} \quad (19)$$

Между чистой текущей стоимостью (NPV) и ставкой дисконтирования (i) существует обратная зависимость. Эта зависимость представлена в таблице 27 и на рисунке 17.

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». Из графика получаем, что IRR составляет 1,14.

Запас экономической прочности проекта: $114\% - 20\% = 94\%$.

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.

Таблица 27 – Зависимость NPV от ставки дисконтирования

№	Наименование показателя	0	1	2	3	4	NPV, руб
1	Чистые денежные потоки, руб	-109052	130863	130863	130863	130863	
2	Коэффициент дисконтирования						
	0,1	1	0,90909	0,82645	0,75131	0,68301	
	0,2	1	0,83333	0,69444	0,5787	0,48225	
	0,3	1	0,76923	0,59172	0,45517	0,35013	
	0,4	1	0,71429	0,5102	0,36443	0,26031	
	0,5	1	0,66667	0,44444	0,2963	0,19753	
	0,6	1	0,625	0,39063	0,24414	0,15259	
	0,7	1	0,58824	0,34602	0,20354	0,11973	
	0,8	1	0,55556	0,30864	0,17147	0,09526	
	0,9	1	0,52632	0,27701	0,14579	0,07673	
	1	1	0,5	0,25	0,125	0,0625	
	1,1	1	0,47619	0,226757	0,10798	0,051419	
	1,2	1	0,45455	0,20661	0,09391	0,04269	
	1,3	1	0,43478	0,18904	0,08219	0,03573	
3	Дисконтированный денежный доход, руб.						
	0,1	-109052	118966	108151	98319,3	89381,2	305766,1
	0,2	-109052	109053	90877,1	75730,9	63109,1	229717,57
	0,3	-109052	100664	77433,7	59564,4	45818,8	174428,75
	0,4	-109052	93473,6	66766,8	47690,6	34064,7	132943,72
	0,5	-109052	87242	58161,3	38774,2	25849,5	100975,04
	0,6	-109052	81789,4	51118,4	31949	19968,1	75772,818
	0,7	-109052	76978,2	45281,3	26636,1	15668,3	55511,893
	0,8	-109052	72701,7	40389,8	22438,8	12466	38944,26
	0,9	-109052	68875,3	36250,1	19079	10041,6	25194,012
	1	-109052	65431,5	32715,8	16357,9	8178,94	13632,063
	1,1	-109052	62315,7	29674,1	14130,5	6728,83	3797,2435
	1,2	-109052	59483,2	27037,8	12289,9	5586,32	-4654,77
	1,3	-109052	56897	24737,8	10755,6	4676,33	-11985,33




Рисунок 17 – Зависимость NPV от ставки дисконтирования

Наиболее приемлемым методом установления дисконтированного срока окупаемости является расчет кумулятивного (нарастающим итогом) денежного потока (таблица 28).

Таблица 28 – Дисконтированный срок окупаемости

№	Наименование показателя	Шаг расчета				
		0	1	2	3	4
1	Дисконтированный денежный доход ($i=0,20$), руб.	-109052	96329,63	80274,67	66895,64	55746,32
2	То же нарастающим итогом, руб.	-109052	-12722,37	67552,30	134447,94	109194,26
3	Дисконтированный срок окупаемости	$PP_{диск} = 1 + (12722,37 / 80274,67) = 1,16$ года				

Социальная эффективность научного проекта (таблица 29) учитывает социально-экономические последствия осуществления научного проекта для общества в целом или отдельных категорий населения или групп лиц, в том числе как непосредственные результаты проекта, так и «внешние» результаты в смежных секторах экономики: социальные, экологические и иные внеэкономические эффекты.

Таблица 29 - Критерий социальной эффективности

ДО	ПОСЛЕ
Трата большого количества времени для выполнения рутинных задач, что ведет к избыточной трате электроэнергии	Экономия электроэнергии за счет использования чат-бота для рутинных задач, так как тратится меньше времени за компьютером для решения тех же задач.

1.2.2 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:

$$I_{\text{финр}}^{\text{исп.}i} = \frac{\Phi_{pi}}{\Phi_{\text{max}}}, \quad (20)$$

где: $I_{\text{финр}}^{\text{исп.}i}$ – интегральный финансовый показатель разработки;

Φ_{pi} – стоимость i -го варианта исполнения;

Φ_{max} – максимальная стоимость исполнения научно-исследовательского проекта (в т.ч. аналоги).

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

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

$$I_{pi} = \sum a_i \cdot b_i, \quad (21)$$

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

a_i – весовой коэффициент i -го варианта исполнения разработки;

b_i^a, b_i^p – бальная 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 (таблице 30).

Таблица 30 – Сравнительная оценка характеристик вариантов исполнения проекта

Критерии \ ПО	Весовой коэф. параметра	Текущий проект	Аналог 1	Аналог 2
1. Способствует увеличению скорости выполнения рутинных задач	0,23	5	4	4
2. Удобство в эксплуатации (соответствует требованиям потребителей, все функции внутри одного приложения)	0,21	5	5	5
3. Безопасность	0,19	4	4	4
4. Надежность	0,19	4	3	3
5. Простота эксплуатации (понятный интерфейс и функции)	0,18	5	4	4
Итого	1	23	20	20

$$I_m^p = 5 \cdot 0,23 + 5 \cdot 0,21 + 4 \cdot 0,19 + 4 \cdot 0,19 + 5 \cdot 0,18 = 4,62$$

$$I_1^a = 4 \cdot 0,23 + 5 \cdot 0,21 + 4 \cdot 0,19 + 4 \cdot 0,19 + 5 \cdot 0,18 = 4,39$$

$$I_2^a = 4 \cdot 0,23 + 5 \cdot 0,21 + 4 \cdot 0,19 + 4 \cdot 0,19 + 5 \cdot 0,18 = 4,39$$

Интегральный показатель эффективности разработки $I_{финр}^p$ и аналога $I_{финр}^a$ определяется на основании интегрального показателя ресурсоэффективности и интегрального финансового показателя по формуле:

$$I_{финр}^p = \frac{I^p}{I_{\phi}^p}; I_{финр}^a = \frac{I^a}{I_{\phi}^a} \quad (22)$$

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

$$\mathcal{E}_{\text{ср}} = \frac{I_{\text{финр}}^p}{I_{\text{финр}}^a}, \quad (23)$$

где: $\mathcal{E}_{\text{ср}}$ – сравнительная эффективность проекта;

$I_{\text{финр}}^p$ – интегральный показатель разработки;

$I_{\text{финр}}^a$ – интегральный технико-экономический показатель аналога.

Сравнительная эффективность разработки по сравнению с аналогами представлена в таблице 31.

Таблица 34 – Сравнительная эффективность разработки

№ п/п	Показатели	Разработка	Аналог 1	Аналог 2
1	Интегральный финансовый показатель разработки	0,9	0,97	1
2	Интегральный показатель ресурсоэффективности разработки	4,62	4,39	4,39
3	Интегральный показатель эффективности	5,133	4,526	4,39
4	Сравнительная эффективность вариантов исполнения	1	0,88	0,855

Вывод: Сравнение значений интегральных показателей эффективности позволяет понять, что разработанный вариант проведения проекта является наиболее эффективным при решении поставленной в магистерской диссертации технической задачи с позиции финансовой и ресурсной эффективности.

В ходе выполнения раздела финансового менеджмента рассчитан бюджет научного исследования, определена чистая текущая стоимость, (NPV), равная 109194,26руб.; индекс доходности $PI=2,744$; внутренняя ставка доходности $IRR=1,14$, срок окупаемости $PP_{\text{дск}}=1,16$ года, тем самым инвестиционный проект можно считать выгодным и экономически целесообразным.

Список публикаций студента

1. Семенов М.Е., Семенов Д.Е., Курбонов К.С. Автоматизация процедуры оценки по компетенциям студентов. Материалы республиканской научно-практической и методической конференции «Важные задачи развития науки информатики и проблемы в его обучении в образовательных учреждениях» – Душанбе, 12 мая 2020 г., с. 199-206

https://www.tgpu.tj/index.php?option=com_content&view=article&id=3170&Itemid=462&lang=ru

2. Назаров А. П., Курбонов К. С. Dictionary development technology in excel spreadsheet // Вестник института развития образования, 2019, 2(26), 203-206

<https://www.elibrary.ru/item.asp?id=39216608>

Заключение

В данной работе рассмотрена математическая модель для интеллектуальной генерации текста для чат-бота. Мы разработали чат-бот с использованием сервиса DialogFlow Google. Разработали корпус вопросов-ответов для обучения чат-бота. В чат-бот был заложен сценарий, в котором диалог осуществляется в зависимости от выбора пользователя.

С помощью API DialogFlow Google на языке Python мы выгрузили диалоги и применили модель для интеллектуальной генерации текста.

Для определения сходства между двумя фразами мы использовали косинусное расстояние. Результаты расчетов показали, что косинусное расстояние между оригинальной фразой и сгенерированными фразами лежит в пределах 0,44 от 0,96.

Список литературы

1. Experimentally induced visual projections into auditory thalamus and cortex/ Sur, M., P.E. Garraghty and A.W. Roe // Science 242 1988.P.1437–1441.
2. Tactile sensory substitution studies / Bach-y-Rita P // Annals of the New York Academy of Sciences -2004. P. 83–91, 2004.
3. Brainport technologies– helping people with disabilities live a better life [electronic resource]/ Wicab, Inc. Middleton, WI, USA / URL: <https://www.wicab.com/>, free access – Lang. Eng. Access date: 25.04.2020
4. Ideas for inspiration [electronic resource] / Pinterest, Inc. at 984 Brannan Street, San Francisco, CA 94107, USA / URL: <https://www.pinterest.com/>, free access – Lang. Eng, Ru. Access date: 25.04.2020
5. Get smarter about what matters to you [electronic resource]: Biological Neurons versus Artificial Network / A Medium Corporation – Author: Swathi Arulgroup Nagendra; Publication date: 25.10.2018 / URL:<https://medium.com/@swaramk/biological-neural-network-vs-artificial-neural-network-69b4fa2b093b>, free access – Lang. Eng. Access date 26.04.2020
6. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain / FrankRosenblatt // Cornell Aeronautical Laboratory,
7. Psychological Review, v65, No. 6 – 1958, P386-408
8. Garcia, Eva & Nogales, Alberto & Escudero, Javier & García-Tejedor, Alvaro. (2020). A light method for data generation: a combination of Markov Chains and Word Embeddings. 10.26342/2020-64-10.
9. Butler analytics – Big data and machine learning in use [electronic resource]: Neural network data mining explained / Butler analytics, Inc. / URL: <https://www.butleranalytics.com/neural-network-data-mining-explained/>, free access
10. Lang. Eng. Access date 26.04.2020
11. Statista – The statistics portal for market data, market research [electronic resource] :Number of mobile phone messaging app users worldwide from 2018 to 2022 (in billions)/ Statista, Inc. / Author: J. Clement, Publication date: 8.10.2019 / URL:

<https://www.statista.com/statistics/483255/number-of-mobile-messaging-users-worldwide/>, free access – Lang. Eng. Access date 01.05.2020

12. Russian Language Neural Net Chat-botwith Natural Language Processing [electronic resource] / N. Ismoilov, M.E. Semenov // 14 International Forum on Strategic Technology (IFOST-2019), October 14-17, 2019, Tomsk, Russia

13. Tomsk: TPU Publishing House– 2019 // URL: http://earchive.tpu.ru/bitstream/11683/57459/1/conference_tpu-2019-C127_p135-138.pdf, free access – Lang. Eng. Access date: 01.05.2020

14. Morph.ai – Having meaningful conversations with your users [electronic resource] / Scupids Tech Private Limited / URL: <https://morph.ai/>, free access – Lang.

15. En. Access date: 28.04. 2020

16. Flow XO – Create a chat-botwith zero coding skills required [electronic resource] / Flow XO LLC / URL: <https://flowxo.com/>, free access – Lang. En. Access date: 28.04.2020

17. Государственная итоговая аттестация./ URL: https://portal.tpu.ru/standard/final_attestation/Tab/6_10_02_2014.pdf free access – Lang.

18. Build natural and rich conversational experiences [e-resource] / Google,

19. Inc. / URL: <https://dialogflow.com/>, free access – Lang. En. Access date: 28.04.2020

20. Head first Python / P. Barry // O’Reilly Media Inc.-2016–624 p.

21. Find, install and publish Python packages with the Python package index [electronic resource]: SciPy/ Python software foundation; Python community / URL: <https://pypi.org/project/scipy/>, free access – Lang. En., Ru., Esp., Fr. Access date: 02.05.2020

22. Встраиваемый чат-бот в готовые корпоративные системы: магистерская диссертация [Электронный ресурс] / Г. С. Чурсин // Национальный исследовательский Томский политехнический университет (ТПУ) // URL: <http://earchive.tpu.ru/bitstream/11683/54985/1/TPU735276.pdf>, Free Access – Lang. Ru., Дата доступа: 10.05.2020

23. Wondererd.net – A nerds home on the net [electronic resource] / Wondererd.net / Deep Learning in Virtual Data Center Management – 2016 / URL: <https://www.wondererd.net/blog/deep-learning-in-virtual-data-center-management/>, free access – Lang. En., Access date: 03.05.2020

24. Natural language processing with Python / S. Bird, E. Klein, E. Loper // O'Reilly Media Inc. – 2009 - 463 p.

25. Coursera | Online Courses & Credentials From Top Educators [electronic resource]: Online course: Natural Language processing – National Research University Higher School of Economics / Coursera, Inc. / URL: <https://www.coursera.org/learn/language-processing/home/>, Access for registered users, Lang. En., Access date: 08.05.2020

26. Sequence to sequence learning with neural networks / Ilya Sutskever, Oriol Vinyals, Quoc V Le // In Advances in neural information processing systems – 2014, P. 3104-3112.

27. Открытые датасеты [electronic resource] / Яндекс / URL: <https://toloka.ai/ru/datasets>, free access, Lang. Ru., Access date: 06.05.2020

28. ГОСТ 12.2.032 -78 ССБТ. Рабочее место при выполнении работ сидя. Общие эргономические требования. М.: Изд-во стандартов, 1986. – 9 с.

29. Санитарно-эпидемиологические правила и нормативы: СанПиН 2.2.4.548–96 Гигиенические требования к микроклимату производственных помещений. М.: Минздрав России, 1997. – 20 с.

30. Свод правил: СП 52.13330.2016. Естественное и искусственное освещение. М.: Минрегион России, 2011. – 74 с.

31. Санитарно-эпидемиологические правила и нормативы: СанПиН 2.2.4.3359-16. Санитарно-эпидемиологические требования к физическим факторам на рабочих местах. М.: Минздрав России, 2003. – 39 с.

32. ГОСТ 12.1.019-2017 ССБТ Электробезопасность. Общие требования и номенклатура видов защиты. – М.: Изд-во стандартов, 2010. – 28 с. ГОСТ 12.1.004-91 ССБТ. Пожарная безопасность. Общие требования. – М.: Изд-во стандартов, 2006. – 67 с.

33. ГОСТ 12.1.010-76 ССБТ. Взрывобезопасность. Общие требования. – М.: Изд-во стандартов, 2003. – 6с.

34. Санитарные правила и нормы СанПиН 2.2.4.548-96 "Гигиенические требования к микроклимату производственных помещений".

35. Санитарные правила и нормы СанПиН 2.2.1/2.1.1.1278-03. Гигиенические требования к естественному, искусственному и совмещенному освещению жилых и общественных зданий – 34с.

36. ГОСТ Р 55710-2013 Освещение рабочих мест внутри зданий– 13с. [33] ФЗ от 24.06.1998 №89-ФЗ (ред. от 25.12.2018) «Об отходах производства и потребления»

37. Распоряжение Правительства РФ от 25.07.2017 №1589-р

38. 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.

39. Singularika | Разработка чат ботов для бизнеса [Электронный ресурс] / Singularika / URL: <https://chat-bots.singularika.com/>, свободный доступ, Яз.рус., Дата обращения: 20.04.2020

40. Ваш личный корпоративный помощник – БОТ [электронный ресурс] / ЗАО «КРОК инкорпорейтед» / URL: <https://bot.croc.ru/>, свободный доступ, Яз. рус., Дата обращения: 20.04.2020

41. Постановление Правительства РФ от 6 ноября 2019 г. N 1407 “О предельной величине базы для исчисления страховых взносов на обязательное социальное страхование на случай временной нетрудоспособности и в связи с материнством и на обязательное пенсионное страхование с 1 января 2020 г.”

Доступ: <https://www.garant.ru/products/ipo/prime/doc/72878832/>

Приложение А

Раздел 1

Generating text based on Markov chains for a chat-bots

Студент:

Группа	ФИО	Подпись	Дата
0ВМ91	Курбонов Комрон Сулаймонович		

Руководитель ВКР:

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

Консультант-лингвист отделения иностранных языков ШБИП:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
доцент	Сидоренко Т В.	к.ф.н.		

Definitions

Application programming interface (API) – is a computer interface which defines interactions between multiple software intermediaries. It defines the kinds of calls or requests that can be made, how to make them, the data formats that should be used, the conventions to follow, etc.

Chat-bot– a program that simulates a person’s speech behavior when communicating with one or more interlocutors.

Context – Can be used “remember” parameter values , so they can be passed between intents.

Entities – Each intent parameter has a type, called the *entity type*, which dictates exactly how data from an end-user expression is extracted.

End-to-End System – a full package of machine learning system that processes data, learns from it and deliver user-friendly results.

Intent – An intent categorizes an end-user's intention for one conversation turn. When an end-user writes or says something, referred to as an end-user expression, matches the end-user expression to the best intent in your agent. Matching an intent is also known as intent classification.

Natural language – a complex system of rules in accordance with which speech activity occurs, i.e. generation and understanding of texts.

Natural language processing – one of the areas of artificial intelligence and mathematical linguistics, which is studying the problems of computer analysis and synthesis of natural languages.

Neural network –a network that simulates human or animal brain with lots of densely interconnected artificial neurons, so that a computer program can learn things, recognize patterns and make decisions in a humanlike way.

Tokenization – the process of demarcating and possibly classifying sections of a string of input characters.

Introduction

Chat-bots are automated systems that help users find answers to their queries. For businesses and organizations, they provide a modern way to communicate with their employees and customers. Chat-bots provide a user-friendly interface for getting answers to queries without a phone call or email.

Chat-bots are used in almost all areas of life, such as services, commerce, entertainment, and consulting, and can be divided into the following groups: question-answering, task-oriented, and social bots. Depending on the group, modern chat-bots have different requirements, in particular: to have conversational abilities, to present semantically correct information and meaningful answers, to be able to learn for a specific subject area. To meet these requirements, various response generation models can be embedded in chat-bots, such as template-based models, targeted search, or a generative approach.

The aim of the work is to develop a mathematical model for automated generation of chat-bot responses.

To achieve this goal, the following tasks were formulated:

- 1) Form a corpus of questions and answers.
- 2) Develop a script for a chat-bot.
- 3) Programmatically implement the unloading of chat-bot dialogs with users.
- 4) Generate texts of responses to user requests with pre-processing (checking for spelling errors, profanity, etc.).

1. Literature review

Chat-bots are automated systems that assist users by responding to their questions. To businesses, they provide an improved way of connecting with their customers and increasing customer satisfaction. To customers, they provide a better and more convenient way of having their questions answered without waiting on the phone or sending many emails. A Forrester study notes that in countries such as South Korea, Singapore, India and the US, chat-bots are the customers' preferred platform for communication with a business. Chat-bots have been applied in various industry sectors such as service, commercial, entertainment and advisory and have been classified into different groups .

The literature classifies chat-bots as either question answering, task-oriented or social bots according to the scope expected from them. Question answering bots are knowledge-based chat-bots that answer users' queries by analysing the underlying information collected from various sources like Wiki, DailyMail, Allen AI science and Quiz Bowl . Task-oriented bots are goal-based chat-bots that assist in achieving a certain task or attempts to solve a specific problem such as a flight booking, hotel reservation etc .Social bots are those that communicate with other users and make recommendations to them , for example Microsoft Xiaoice and Replika . When a chat-bot is used by a business to answer users' queries with a specific goal or focus on the completion of certain tasks requested by their customers, it is referred to as a service-based chat-bot. Such chat-bots are domain-specific and may use one of the above-mentioned classifications to generate a response. A key requirement for service-based chat-bots is for them to engage with the customers. This is important as figures show that 91% of unhappy customers will not engage with the business again . One requirement for chat-bots to have while engaging with the users is to show empathy in their responses rather than just using their conditional response library . For example, in response to the user's questions 'I am not feeling well' and 'I am sad', a chat-bot using its conditional response library would just mention 'How can I help you?' for both the questions. But a human being would reply 'How can I help you? Do you need medical help?' and 'I am sorry to hear that. Why are you

sad?’ respectively. The human response shows the presence of empathy that will relate more to the user, which chat-bots should have in their response. This is mentioned in the literature that chat-bots that assist in customer support should not come off as too serious and transactional, as they do not inspire continued use . So, a service-based chat-bot needs to keep the customers engaged and have dialogue abilities rather than just providing either a yes or no to a short response. Dialogue abilities enable the chat-bot to converse with the user according to the terminology of the specific domain. Dialogue-based chat-bot is a conversational AI assistant which needs to meet the following requirements:

-

Requirement 1 (R1): Have conversational capabilities. Conversations are the core of a chat-bot. However, to be engaged with the users, rather than just providing a short yes or no answer, the chat-bot should generate accurate and meaningful responses by identifying the intent, entity and context awareness .

-

Requirement 2 (R2): Present semantically correct information. Semantics help to bring the correct meaning for a word according to the context of a sentence. For example, the word ‘create’ can mean build, make, construct or compose. When the context of the sentence is database creation, the word ‘build’ is more appropriate than ‘compose’. Thus, chat-bot responses should be syntactic and pragmatic according to the context of the information presented .

-

Requirement 3 (R3): Present meaningful responses. When generating a response, the chat-bot should not only give a response which is semantically correct, it should also provide significant detail for easy understanding For example, in response to the question “What day it is today?”, a semantically correct response is ‘Tuesday’, but a meaningful response would be ‘Tuesday, 30th July 2019’.

-

Requirement 4 (R4): Trained on a domain-specific dataset. In order to build a domain-oriented chat-bot, it needs to be trained on a specific domain rather than just

simple dialogue dataset such as the Cornell movie dialogue and Twitter dataset so the chat-bot will be able to understand domain-specific terms, information and workflow.

The aim of this paper is to study the effectiveness of existing approaches in generating a response that is not only semantically correct but also meaningful while engaging the user in conversation. The shortcomings of the existing approaches in meeting these requirements are identified. It then proposes a multi-strategy selection-based QA chat-bot framework, termed IntelliBot that determines which strategy to use to engage with the user in dialogue while generating a response. This study tested and validated the performance of the chat-bot in the insurance domain. The structure of the paper is as follows. Section 2 discusses the process by which a chat-bot generates a response and the requirements of a dialogue-based chat-bot. Section discusses the existing techniques used in the literature to generate a response from chat-bots, along with discussing their shortcomings from the viewpoint of a dialogue-based chat-bot.

2. Dialogue-based chat-bot

Dialogue-based chat-bots are designed to engage with the user for extended conversations. To do this, multiple components in the chat-bot are required discusses the need for Interface, Data Processing and Integration components. The interface component links the chat-bot with the user through an app or webpage. It captures the user's questions and conveys the response. The data processing component understands the captured question and transforms it into information. Different natural language processing (NLP) techniques are used for the chat-bot engine to understand what the customer is asking and develop a response to it using one of the response-generating models. The third component links the chat-bot to existing systems, platforms and databases for it to access the required information.

As discussed previously, the paper's focus is on a chat-bot's operation in generating a response. Thus, it is assumed that the chat-bot has the required interface and access to all information sources. From this perspective, as represented in Fig. 1, a response-generating chat-bot needs to have three different components to engage

with the user for extended conversations. They are input processing, language understanding and response generation.

Input processing component. This component processes the user's input, which can either be in text or speech form using NLP techniques. The goal is to clean the user input text for better knowledge discovery. Various techniques such as lower-casing, punctuation filtering, stop words removal and word segmentation are used to process the input for further processing by the next component.

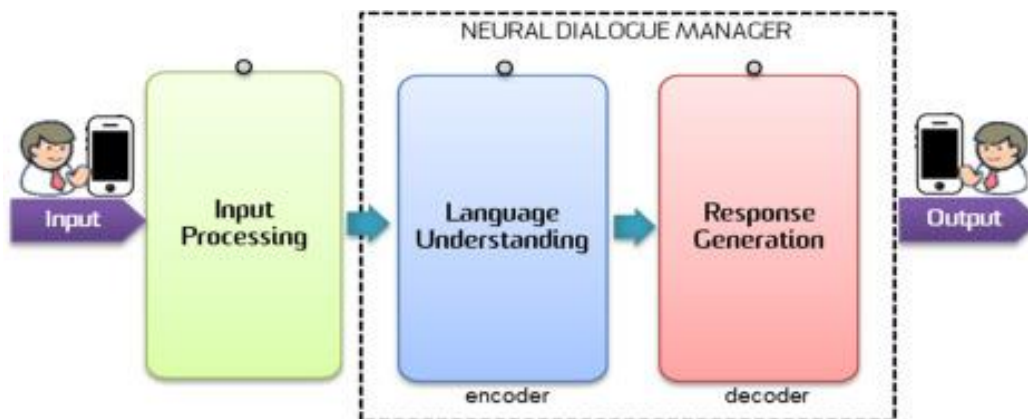


Fig. 1. Different components required in a response-generating chat-bot application.

Language understanding component. This component understands the user's question by taking the word segments as its input. Different techniques such as tokenization, POS tagging, named entity recognition, lemmatization, context identification, sentiment analysis, query classification etc. are used.

Response generation component. This component generates a response to the user's question by accessing the required data from multiple information sources. The response will be generated according to one of the four models being used, as follows:

1.

Template-based model: This model has pre-defined questions and answers. It matches the users' question based on the pre-defined collection of rules, question template and in the case of a match, displays their answer to the user. Such chat-bots work on determining patterns using rules and are commonly used in the

entertainment industry. Examples of these types of chat-bots are Alicebot , Elizabot , Chat Script , and Story-bot . The template-based model uses the Artificial Intelligence Markup Language (AIML) , ChatScript, RiveScript and Rasa to structure the responses. To bootstrap user-bot interaction, an initiator model is used that acts as the conversation starter . Some applications of this model are Storybot and BoW movies which respond with a story and with the movie title, actors' names etc., respectively. However, the common drawback with this type of model is that the user gets a response only if there is a high level of pattern similarity between the input questions and sometimes the response is inappropriate.

2.Retrieval-based model: This model is more advanced than the template-based model in that it not only finds the matches between the user's and the predefined question, it also considers the intent of the conversation. To understand the intent of the conversation, such models use techniques such as recurrent neural networks, a logistics regression classifier and sequence-to-sequence. Based on these, the underlying database is searched for an answer. To select a response, information is retrieved from the knowledge-base, such as previous conversational history, logs, PDS and insurance domain-specific terms. It applies a complex semantic query formation technique to obtain information and matches this using an ensemble of machine learning classifiers. As is the case with the template-based model, this model constructs a response through keywords, identified facts and semantic query formation for corresponding questions. Examples where this type of chat-bot has been applied is the BoW escape plan . Using a logistics regression classifier, the chat-bot aims to engage with the user and provides responses from 35 different topics. The work in develops a dual encoder model that uses recurrent neural networks and sequence encoders to generate a response. The work in uses the sequence-to-sequence approach with Gaussian latent variables that use a logistics regression model to generate responses from Reddit data. The work in uses a bag-of-words model with the Word2Vec approach to select a response from the underlying dataset that has the highest cosine similarity. So, while these models generate a response, they may be inappropriate and need a large amount of data to

be reasonably functional.

3. Search engine-based model: This model generates a response by crawling the web or using search engine results using a deep classifier model. Information retrieval using web crawling or search engines is not as simple as searching a knowledge base. It first needs to identify semantic annotations or metadata from the semantic layer of the web. Then, it needs to apply DOM parsing and extract only the required and relevant data that contains an answer. The search engine model uses approaches such as a deep classifier or an LSTM classifier to generate a response from the search results. Techniques such as deep brain and deep learning are used to identify the possible answer before selecting the one to be shown to the user. While the scope from where the answer is chosen is increased in this model from the previous ones, the challenge is to select the most appropriate response from the many possible answers. Examples of such chat-bots are Indri, Google Assistant, Microsoft Bing, Lucene .

4. Generative-based model: Generative-based models generate new answers in response to users' questions. They do not depend on pre-defined questions and answers, rather they use neural network models or deep learning techniques such as ANN, RNN, CNN and Deep Q to develop a dialogue with the user on the fly. The generative model uses a knowledge synthesis approach to generate answers and engage with the users in the form of a dialogue. These models generate responses by translating from the inputs to the outputs. Various chat-bots that use this model have been developed. The work in developed a Question Generator Unit (GRU) that generates follow-up questions to be presented to the user using a word-by-word vector. The work in proposed the Seq2Seq Model which is a feed forwarder fully connected neural network to generate a response. The Deep-Q-Network works on the end-to-end decoder approach and uses an iterative decoding strategy to obtain an output sequence with maximal probability. The research in , proposed the Markov chain model that builds responses which have the highest probability using the stochastic model and Markov process. The work in proposed the pipeline method which is a task-oriented dialogue system method using neural networks and

deep learning. These models, however, have drawbacks as they need large training data, longer training time, and significant human input to correctly train them so that they give satisfactory performance.

As this study focusses on chat-bots that engage with users for extended conversations, all the four above-mentioned models fit the scope of the study. In the next sub-section, the techniques used in existing dialogue-based chat-bot to generate a response are discussed.

Natural language processing (NLP) is the underlying philosophy used by dialogue-based chat-bot to generate responses. Recent advances such as deep learning have been used to build intelligence for chat-bots to engage in a conversation with a human using techniques such as recurrent neural networks (RNNs), deep neural networks (DNNs) and convolutional neural networks (CNNs). These techniques use approaches such as seq2seq, word2vec, TF-IDF, end-to-end, attention mechanism etc. to train the model. The next sub-section presents a summary of each technique and a comparison is conducted to identify the gaps from the perspective of meeting the requirements needed from response-generating chat-bots.

Generating text using Markov chains

Most modern natural language processing techniques are highly data dependent. Machine learning models require a significant amount of data to train, and in some scenarios the data may not be sufficient.

In this paper, we propose to use the method of generating new responses to user requests (suggestions) to expand the training data. Our approach uses Markov chains.

A Markov chain is a statistical model that can be used for sequential processing of words. Chains allow you to calculate the probability of occurrence of the observed events (in our case, which word is best suited in a certain place of the sentence) [9].

A sequence of discrete random variables $\{X_n\}$, $n \geq 0$ will be called a simple Markov chain (with discrete time) if

$$\mathbf{P}(X_{n+1}=i_{n+1} | X_n=i_n, X_{n-1}=i_{n-1}, \dots, X_0=i_0) = \mathbf{P}(X_{n+1}=i_{n+1} | X_n=i_n). \quad (1)$$

Formula (1) specifies the conditional distribution of the subsequent state of the Markov chain, which depends only on the current state and does not depend on all previous states. In this case, $\{X_n\}$ is called the state space of the chain, and n is called the step number. The matrix $P_{ij}(n) = \mathbf{P}(X_{n+1}=j | X_n=i)$ is called the transition probability matrix at the n th step, and the vector $\mathbf{p}=(p_1, p_2, \dots)$ is called the initial distribution of the Markov chain. The matrix $P_{ij}(n)$ is stochastic and the normalization condition is satisfied for it.




Figure 1.2 Markov chain with four states

Algorithm for generating text.

1. Divide the original text into words.
2. Combine all words that are next to each other in pairs.
3. Using these pairs, compile a dictionary of strings, where the first word and all words that may come after it are indicated.
4. Pick a random word to get started.

5. Set the length of the desired text and choose a random word to get started.

To illustrate the operation of this algorithm, we used the first two paragraphs from this section as the source text and generated it with a length of 6 words. As a result, we got the phrase "responses to user requests (proposals) for".

The complete Python code is available at <https://colab.research.google.com/drive/1Xep7jg14Xs1vu0WeawLjrkuipjHymkMx#scrollTo=daRj6wDKu9rk>

Further, this algorithm can be applied cyclically and get a new phrase.

Different distances can be used to determine the similarity between two phrases, such as Levenshtein distance, N-gram distance, and cosine distance.

Levenshtein distance measures in absolute value the difference between two sequences of characters (words). This distance is defined as the minimum number of single-character operations (insert, delete, replace) required to transform one sequence of characters into another. To calculate the N-gram distance, you need to split the string into substrings of length N and count the number of matching substrings. To calculate the cosine distance, you need to convert two text strings X, Y into two binary vectors: if the words match, then the elements of the vectors are equal to 1, otherwise 0. The final formula will look like:

$$\cos(X, Y) = \frac{\sum_{i=1}^n (X_i - Y_i)}{\sqrt{\sum_{i=1}^n (X_i)^2} \sqrt{\sum_{i=1}^n (Y_i)^2}} \quad (2)$$

Note that the application of formula (2) requires preliminary preprocessing of the text (lemmatization), that is, the conversion of the text to the dictionary form.

In Russian, the following forms are considered to be vocabulary:

- for nouns - nominative, singular;
- for adjectives - nominative, singular, masculine;
- for verbs, participles, gerunds - the verb in the infinitive.

3. practical part

3.1. Formation of the corpus of questions and answers

As the subject area of the chat-bot, we chose educational activities and developed an intellectual assistant for TPU students and teachers.

To form the corpus of questions and answers, we used the questions of TPU students, which they asked during the preparation and implementation of research work in the semester, technological and industrial practice for 2020-2021, and to formulate the answers we used the regulatory documents of educational activities [12]. Let's give as an example one question and the answers to it:

Вопрос	Ответы	
Какие разделы должны быть в магистерской диссертации?	1	Обычно диссертация включает 10 разделов: Содержание, Аннотация, Введение, Постановка задачи, 1. Обзор известных методов и средств решения проблемы, 2. Исследование и построение решения, 3. Описание практической части, Заключение, Список цитируемой литературы и Приложение(я).
	2	Необходимые разделы диссертации перечислены в Регламенте, на странице
	3	Основные разделы диссертации это 1. Обзор известных методов и средств решения проблемы, 2. Исследование и построение решения, 3. Описание практической части. Более подробно смотри регламент на странице <###>
	4	Пояснительная записка к диссертации включает 10 основных разделов, подробнее описание смотри в регламента на странице .
	5	Как правило, диссертация включает 10 основных разделов, подробнее описание смотри в регламента на странице .

We have put a script in the chat-bot, in which the dialogue is carried out depending on the user's choice: for example, electronic approval or paperwork. It depends on what the chat-bot will offer next: the website address for downloading documents or the audience / building number and office hours for document approval.

A complete list of questions and answers can be found in Appendix 1.

3.2. Software implementation and development of a chat bot

To create a chat-bot, we used the Dialogflow natural language cloud service (<https://dialogflow.cloud.google.com/>).

To start working with the service, we made the language settings of the chat-bot (in terms of Dialogflow, the chat-bot is called an agent) and added questions (Intents - intentions, goals) and training answers (Training phrases) from our corpus of questions and answers to it, and also configured entities (Entities) and contexts (Contexts) for conducting dialogues.

For unloading, text processing and text generation, we used the Python language. The launch is performed using the following commands with keys.

To check the base of answers for the presence of profanity:

```
python3 main.py - task profanity
```

To check for syntax errors:

```
python3 main.py - task spellchecking
```

Generating text based on existing dialogs:

```
python3 main.py - task generate
```

The complete program code is given in Appendix 2.

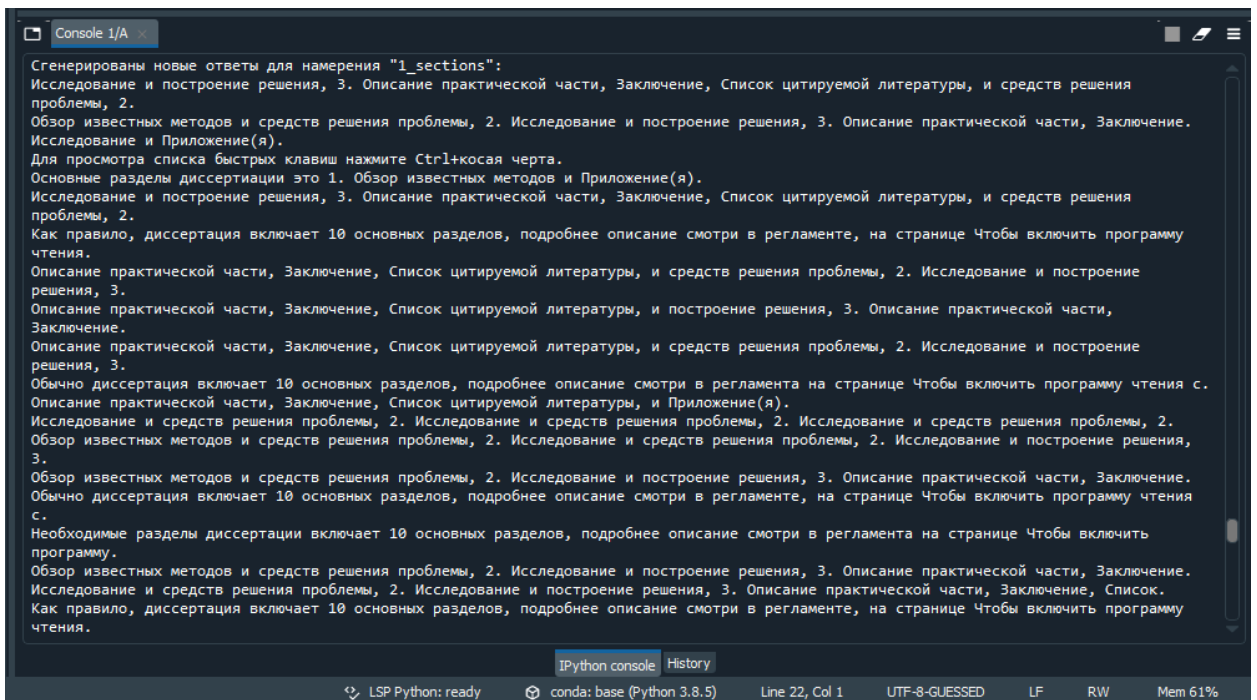


Figure 3.5. An example of generated text based on intent

To assess the quality between the original and the generated sentences, we used cosine similarity (2). The program code is given in Appendix 3.

Table 2 shows the cosine similarity between the original X and the generated sentences (intentions) $Y_i, i = 1, 2, \dots, 20$.

Dialogflow has a built-in learning tool for analyzing, importing and exporting conducted dialogs. By default, training is performed automatically every time the chat-bot is saved on the server side. Dialogues can be displayed in the form of a diagram (Figure 3.6). Rectangles on the transition graph indicate intentions, while green indicates the initial intention (launching a chat-bot), blue - intentions during a dialogue, arrows are transitions from one intention to another, a red rectangle indicates a reserve intention (the chat-bot sets a clarifying question), the numbers (in percent) on the arrows correspond to the probability of transition from one intention (parent) to another (child).

Table 2. Cosine similarity between original and generated sentences

N		Cos(X, Y_i)
3	Intent_4	0.444750
1	Intent_2	0.470871

10	Intent_11	0.518563
9	Intent_10	0.668648
7	Intent_8	0.676123
8	Intent_9	0.801388
4	Intent_5	0.816497
11	Intent_12	0.816497
2	Intent_3	0.836242
5	Intent_6	0.840168
12	Intent_13	0.858116
13	Intent_14	0.930949
14	Intent_15	0.945905
15	Intent_16	0.948683
0	Intent_1	0.955330
6	Intent_7	0.968246

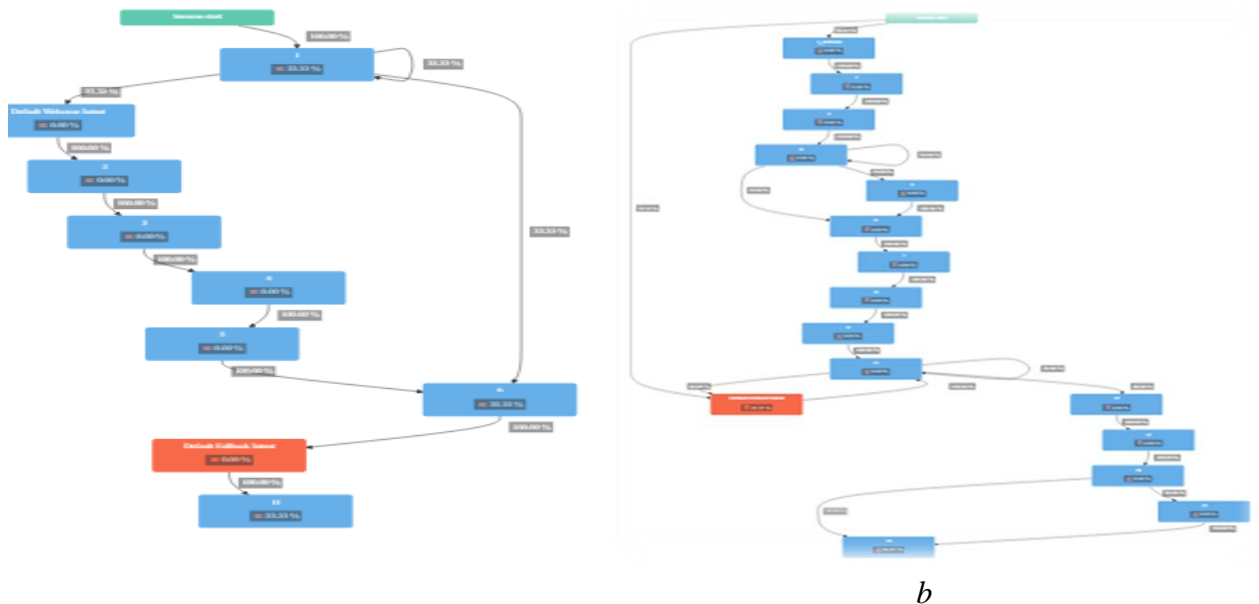


Figure 3.6. Chat-bot transition diagram between intents: a) without human training, b) after human training

Also, training can be performed in manual mode (Figure 3.7), for this you need to select a dialog and place labels (correct, incorrect).

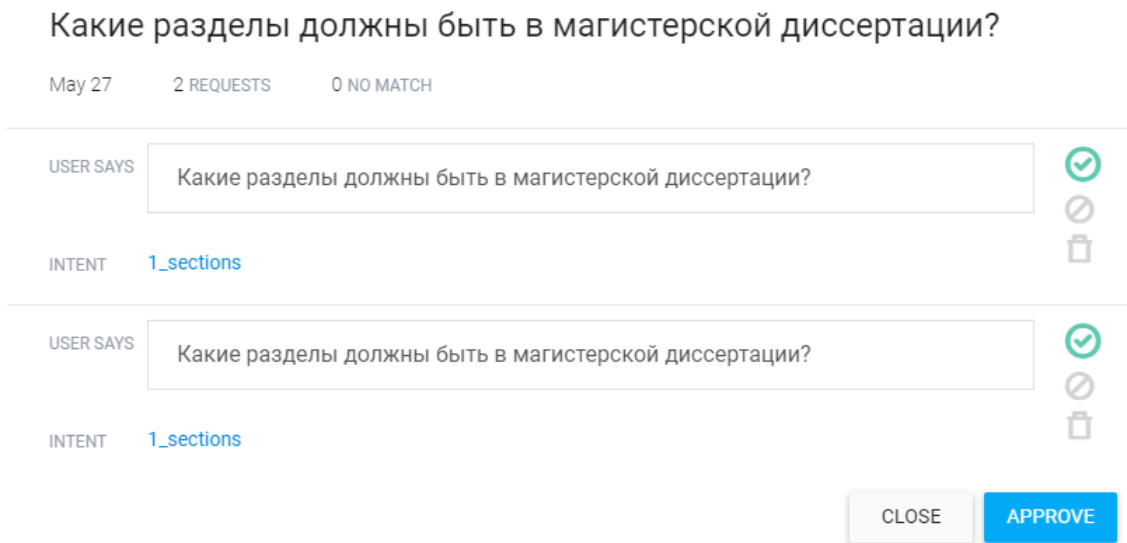


Figure 3.7. List edit displayed

As you can see from Figure 3.6, the transition diagram after manual training has changed.

3.3. Integration of a chat bot with the Telegram messenger

The developed chat-bot can be integrated into the corporate system in various ways. Possible ways to integrate a chat-bot are shown in Figure 3.1.

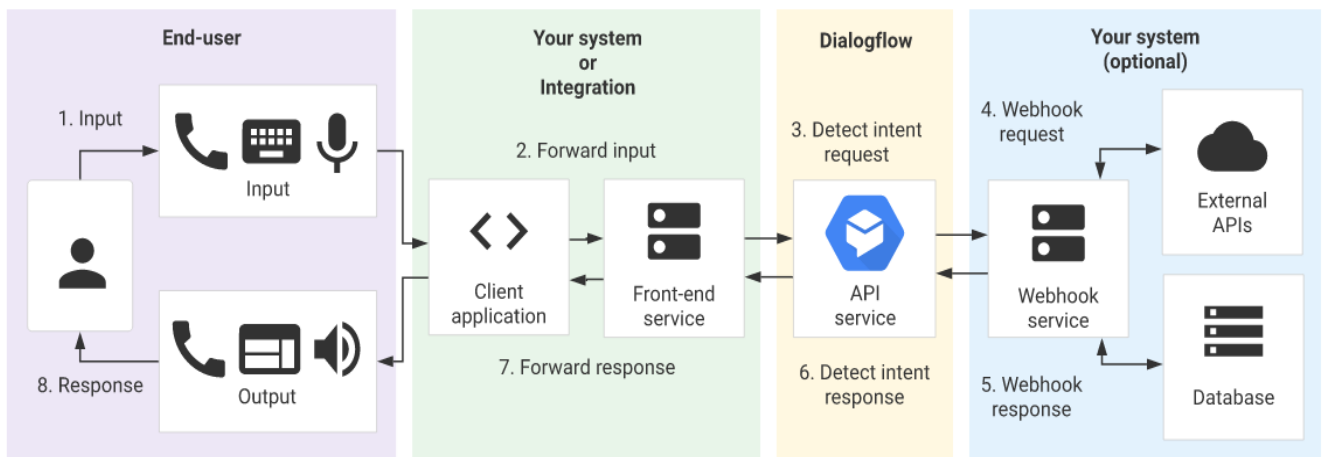


Figure 3.1. Scenario diagram for chat-bot

For the practical use of the developed chat bot, we integrated it with the Telegram messenger.

An account is required to integrate a chat-bot into Telegram. The following are the main points for creating a chat-bot:

1. Open a dialogue with BotFather and start creating - / start,
2. Create a new chat-bot with the / newbot command,
3. Enter the original name of the chat-bot(in our case TPU_VKR),
4. Get the generated access token.

The access token allows you to identify the user and contains information about the security of the session. The marker is entered when installing the integration process in Dialogflow, after which a link to the created bot appears in the dialogue with BotFather. This link serves as an invitation to dialogue with the chat-bot.

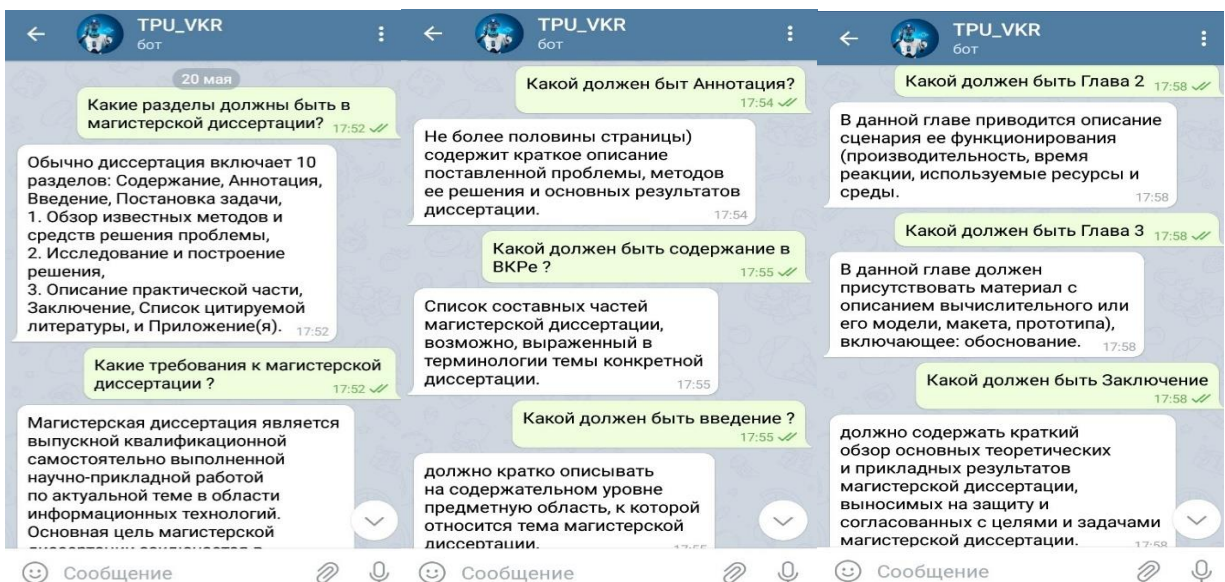


Figure 3.17. An example of dialogues via the Telegram messenger

As you can see from Figure 3.17, when entering questions (green fields), the user makes mistakes, but the developed chat-bot answers the questions correctly.

Приложение 1. Список вопросов и ответов .

Вопрос	Ответы	
Какие разделы должны быть в магистерской диссертации?	1	Обычно диссертация включает 10 разделов: Содержание, Аннотация, Введение, Постановка задачи, 1. Обзор известных методов и средств решения проблемы, 2. Исследование и построение решения, 3. Описание практической части, Заключение, Список цитируемой литературы и Приложение(я).
	2	Необходимые разделы диссертации перечислены в Регламенте, на странице <###>
	3	Основные разделы диссертации это 1. Обзор известных методов и средств решения проблемы, 2. Исследование и построение решения, 3. Описание практической части. Более подробно смотри регламент на странице <###>
	4	Пояснительная записка к диссертации включает 10 основных разделов, подробнее описание смотри в регламента на странице <###>
	5	Как правило, диссертация включает 10 основных разделов, подробнее описание смотри в регламента на странице <###>
Какие требования к магистерской диссертации ?	1	Магистерская диссертация является выпускной квалификационной самостоятельно выполненной научно-прикладной работой по актуальной теме в области информационных технологий. Основная цель магистерской диссертации заключается в проведении самостоятельного научного исследования и разработки решений актуальной проблемы в области информационных технологий с использованием современных методов и средств, а также в обобщении результатов работы и разработке обоснованных рекомендаций и предложений по их практическому использованию.
	2	
Какие общие требования к магистерской диссертации ?		Магистерская диссертация должна демонстрировать получение магистром углубленных теоретических и практических профессиональных знаний и умений, приобретение необходимых личностных качеств для самореализации в таких видах деятельности, как научно-исследовательская, проектная и производственно-технологическая, организационно-управленческая, а также инновационная деятельность.
Какие требования к содержанию магистерской диссертации ?		Магистерская диссертация представляет собой пояснительную записку, включающую следующую последовательность составных частей диссертации в заданном порядке: <ul style="list-style-type: none"> • Титульный лист • Содержание • Аннотация • Введение • Постановка задачи • 1. Обзор известных методов и средств решения проблемы • 2. Исследование и построение решения • 3. Описание практической части • Заключение • Список цитируемой литературы • Приложение(я) (*) (*) Примечание. В приведенном выше списке составных частей магистерской диссертации единственной необязательной составляющей является

Какой титульный лист должен быть ?	1	Образец титульного листа представлен в приложение 1. Титульный лист в формате MS Word можно скачать с сайта магистратуры (Титульный лист.doc).
Какой должен быть Аннотация?	1	не более половины страницы) содержит краткое описание поставленной проблемы, методов ее решения и основных результатов диссертации.
Какой должно быть содержание в ВКР?	1	список составных частей магистерской диссертации, возможно, выраженный в терминологии темы конкретной диссертации.
Какой должен быть введение ?		должно кратко описывать на содержательном уровне предметную область, к которой относится тема магистерской диссертации.
Какой должна быть постановка задачи в ВКР?		должна содержать описание некоторой проблемы в рассматриваемой предметной области, обоснование актуальности решения этой проблемы, определение требований к искомому решению, формулировку целей и задач магистерской диссертации.
Какой должен быть Глава 1 «Обзор известных методов и средств решения проблемы» в ВКР?		должна содержать явно сформулированные цели и критерии сравнения, которые должны соответствовать требованиям к искомому решению исследуемой проблемы, включать анализ релевантных международных стандартов по теме исследования, материал с обстоятельным сравнением и оценкой известных научных, методологических, технологических, алгоритмических, программных решений по теме исследования. В конце обзора должны быть сформулированы выводы с обоснованием выбранного подхода (методологии, методов, средств, алгоритмов, программных решений) для достижения целей диссертации.
Какой должен быть Глава 2 «Исследование и построение решения»		является основной по содержанию, носит теоретический характер, ее материал должен отличаться новизной и оригинальностью. В данной главе разрабатываются или совершенствуются: методологии, модели, методы, средства, алгоритмы, программные решения, позволяющие решить поставленную проблему. В ней также описываются показатели для количественной или качественной оценки предлагаемых решений, позволяющие оценить корректность, полноту и обоснованность результатов диссертации. Глава должна завершаться краткими выводами, резюмирующими основные теоретические решения, полученные в результате проведенного исследования.
Какой должен быть Глава 3 «Описание практической части»		содержит материал прикладного характера, подтверждающий возможность и практичность использования полученных во второй главе теоретических решений на практике. В данной главе приводится описание программной реализации предложенных решений (в виде законченного программного средства или его модели, макета, прототипа), включающее: обоснование выбранного инструментария и среды реализации, описание общей архитектуры программной реализации (с иллюстрацией), описание сценария ее функционирования (с иллюстрацией) и характеристик функционирования (производительность, время реакции, используемые ресурсы и т.п.), а также спецификацию новых функциональных возможностей, если программная реализация осуществляется на основе доработки существующего средства. Далее в главе должен присутствовать материал с описанием вычислительного или тестового эксперимента программной реализации с анализом результатов эксперимента, подтверждающих достижение целей магистерской диссертации. В заключение главы должны быть сформулированы рекомендации по использованию

		результатов диссертации на практике, намечены возможные направления для их развития.
Какой должен быть Заключение		должно содержать краткий обзор основных теоретических и прикладных результатов магистерской диссертации, выносимых на защиту и согласованных с целями и задачами магистерской диссертации.
Какой должен быть Список литературы		должен содержать не менее 30-40 источников по теме исследования, расположенных в порядке появления ссылок на источники в тексте диссертации. На все источники, упомянутые в списке должны быть ссылки в тексте диссертации.
Какой должен быть Приложение		не обязательная составная часть магистерской диссертации. Оно включает вспомогательную информацию, способствующую пониманию диссертации, или техническую информации, которая, будучи включенной в основной текст диссертации, затрудняла бы его понимание. В приложения обычно включаются схемы алгоритмов и программ, листинги программ, результаты вычислительных экспериментов, и т.п. Магистерская диссертация может включать одно или большее число приложений.
Какой должен быть Требования к оформлению текста магистерской диссертации		Магистерская диссертация на защите оценивается, исходя из степени выполнения студентом вышеперечисленных требований к содержанию, а также с учетом качества оформления магистерской диссертации.

Приложение 2. Код программы для обработки и генерации текста

text_generate.py

```
import random

from google.cloud import dialogflow

class Dictogram(dict):

    def __init__(self, iterable=None):
        super(Dictogram, self).__init__()
        if iterable:
            self.update(iterable)

    def update(self, iterable, **kwargs):
        for i in iterable:
            if i in self:
                self[i] += 1
            else:
                self[i] = 1

    def get_weighted_random_word(self):
        weight = self._get_random_weight()
        return self._get_random_item_by_weight(weight)[0]

    def _get_random_weight(self):
        weight_limit = sorted(self.items(), key=lambda x: x[1], reverse=True)[0][1]
        return random.randint(1, weight_limit)

    def _get_random_item_by_weight(self, weight):
        items = [i for i in self.items() if i[1] >= weight]
        return random.sample(items, 1)[0]

class MarkovChain:

    def __init__(self, order=1):
        self.model = {}
        self.N = order

    def parse_and_add(self, string):
        data = []
        words = [w.strip() for w in string.split()]
        is_end_of_sentence = False
        for word in words:
            data.append(word)
            if is_end_of_sentence:
                self.add(data)
                data = [word]
                is_end_of_sentence = False
            if word[-1] in (',', '?', '!):
```



```

        is_end_of_sentence = True
    self.add(data)
def add(self, data):
    for i in range(len(data) - self.N):
        window = tuple(data[i: self.N + i])
        if i == 0:
            self._add_start_window(window)
        if window not in self.model:
            self.model[window] = Dictogram([data[i + self.N]])
        else:
            self.model[window].update([data[i + self.N]])
def generate_sentence(self, length):
    window = self._get_start_window()
    window_str = ''.join(window)
    sentence = [window_str]
    length -= len(window_str)
    while True:
        need_capitalize = sentence[-1][-1] in ('?', '!', '.')
        if window not in self.model:
            return self._get_joined_sentence(sentence)
        word = self.model[window].get_weighted_random_word()
        length = self._get_length_limit(length, word)
        if length < 0:
            return self._get_joined_sentence(sentence)
        sentence.append(word)
        window = tuple([sentence[-self.N]])
        if need_capitalize:
            sentence[-1] = sentence[-1].capitalize()
def _get_start_window(self):
    return self.model['START'].get_weighted_random_word()
def _add_start_window(self, window):
    if 'START' not in self.model:
        self.model['START'] = Dictogram([window])
    else:
        self.model['START'].update([window])
@staticmethod
def _get_length_limit(length, word):
    length -= len(word) + 1
    if length == 0:
        if word[-1] in (',', '?', '!):

```

```

        return length
    return length - 1
return length
@staticmethod
def _get_joined_sentence(sentence):
    while sentence[-1][-1] in (',', ':', ';'):
        sentence[-1] = sentence[-1][:-1]
    if sentence[-1][-1] not in ('!', '?', '!'):
        sentence[-1] += '!'
    sentence[0] = sentence[0].capitalize()
    return ' '.join(sentence)

class Generator:
    def __init__(self, project_id):
        self.intents_client = dialogflow.IntentsClient()
        self.project_id = project_id

    def execute(self):
        parent = dialogflow.AgentsClient.agent_path(self.project_id)
        intents = self.intents_client.list_intents(request={'parent': parent})
        for intent in intents:
            chain = MarkovChain()
            messages = intent.messages[0].text.text
            if messages != []:
                for message in messages:
                    chain.parse_and_add(message)
                print('Сгенерированы новые ответы для намерения "%s":' % intent.display_name)
                for i in range(20):
                    print(chain.generate_sentence(140))
                print('\n')

```

main.py

```

import configparser
import argparse
import sys
import json
import os

parser = argparse.ArgumentParser(description='Process some integers.')
parser.add_argument('-task', '--task', required=True, choices=['spellchecking', 'profanity', 'generate'], help='Spell checking in bot responses')

try:
    param = parser.parse_args()
except IOError as msg:

```

```

    parser.error(str(msg))
config = configparser.ConfigParser()
config.read('config.ini')
project_id = config['DIALOGFLOW']['project_id']
path_to_key = config['DIALOGFLOW']['path_to_key']

os.environ["GOOGLE_APPLICATION_CREDENTIALS"] = path_to_key
if param.task == 'spellchecking':
    from spellchecking import Spellchecking
    spellchecking = Spellchecking(project_id)
    spellchecking.execute()
elif param.task == 'profanity':
    if os.name != 'nt':
        from profanity import Profanity
        slang_detected = Profanity(project_id)
        slang_detected.execute()
    else:
        print('Данная операция не поддерживается на Windows')
        exit(0)
elif param.task == 'generate':
    from text_generate import Generator
    generator = Generator(project_id)
    generator.execute()
spellchecking.py
#!/usr/bin/env python
from google.cloud import dialogflow
import json
import enchant
import string
import requests
SYMBOLS = ["?", "!", ".", ",", ":", "-"]
class Helper:
    def __init__(self):
        self.latest_error_request = ""
        try:
            self.enchant = enchant.Dict("ru_RU")
            self.activity = True
        except enchant.errors.DictNotFoundError:
            print('Добавьте поддержку русского языка')
            self.activity = False

```

```

def check_errors(self, request:str)->list:
    if self.activity and self.latest_error_request != request:
        list_request = request.split()
        for i in list_request:
            if not self.enchant.check(i):
                self.latest_error_request = request
                return {'status': False, 'word_with_error': i, 'options': self.enchant.suggest(i)}
        self.latest_error_request = ""
    return {'status': True}

def remove_punctuation_marks(self, message):
    for s in SYMBOLS:
        message = message.replace(s, "")
    return message

def google_ckeck(self, message):
    xml = """
    <?xml version="1.0" encoding="UTF-8" ?><br/>
    <spellrequest textualreadyclipped="0" ignoredups="0" ignoredigits="1" ignoreallcaps="1"><br/>
    <text>%s</text><br/>
    </spellrequest>
    """ % message
    response = requests.post("https://google.com/tbproxy/spell?lang=ru", data=xml.encode('utf-8'))

class Spellchecking:
    def __init__(self, project_id):
        self.helper = Helper()
        self.intents_client = dialogflow.IntentsClient()
        self.project_id = project_id
        self.found = False

    def execute(self):
        parent = dialogflow.AgentsClient.agent_path(self.project_id)
        intents = self.intents_client.list_intents(request={'parent': parent})
        for intent in intents:
            messages = intent.messages[0].text.text
            for message in messages:
                clean_message = self.helper.remove_punctuation_marks(message)
                result = self.helper.check_errors(clean_message)
                if not result['status']:
                    self.found = True
                    error = 'В намерение "%s" найдена ошибка "%s". Сообщение: "%s" \n' % (intent.display_name,
                    result['word_with_error'], message)
                    print(error)

```

```

        if not self.found:
            print('Ошибка не найдено')

profanity.py
import re
import locale
from google.cloud import dialogflow
expr = r'(?!\b(?:<=|_))(\?:' + expr + r')(\?:\b(?:<=|_))'
class Profanity:
    def __init__(self, project_id):
        self.intents_client = dialogflow.IntentsClient()
        self.project_id = project_id
        self.found = False
    @staticmethod
    def check_profanity(string):
        global expr
        oldloc = locale.getlocale(locale.LC_CTYPE)
        locale.setlocale(locale.LC_CTYPE, 'ru_RU.CP1251')
        expr = expr.encode('windows-1251')
        p = re.compile(expr, re.IGNORECASE | re.LOCALE)
        string = string.encode('windows-1251')
        match = p.search(string)
        locale.setlocale(locale.LC_CTYPE, oldloc)
        if match:
            return True
        return False
    def execute(self):
        parent = dialogflow.AgentsClient.agent_path(self.project_id)
        intents = self.intents_client.list_intents(request={'parent': parent})
        for intent in intents:
            messages = intent.messages[0].text.text

            for message in messages:
                result = self.check_profanity(message)
                if result:
                    self.found = True
                    error = 'В намерение "%s" найдена ненормативная лексика. Сообщение: "%s" \n' %
(intent.display_name, message)
                    print(error)
        if not self.found:
            print('Ненормативной лексики не найдено')

```

Приложение 3. Косинусное сходство между оригинальным и сгенерированными предложениями

```
from collections import Counter
import pandas as pd
```

In [75]:

```
nw=[u'Образец',u'титульного',u'листа',u'представлен',u'в',u'формате',u'MS',u'Word',u'можно',u'скачать',u'с',u'сайта',u'магистратуры',u'(Титульный лист.doc.)']
org=[u'Образец',u'титульного',u'листа',u'представлен',u'в',u'приложение',u'1.',u'Титульный',u'лист',u'в',u'формате',u'MS',u'Word',u'можно',u'скачать',u'с',u'сайта',u'магистратуры',u'(Титульный лист.doc).']
a_nw = Counter(nw) # int 12 кор мекна
b_nw = Counter(org)
words = list(a_nw.keys() | b_nw.keys())
a_vect = [a_nw.get(word, 0) for word in words] # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]
len_a = sum(av*av for av in a_vect) ** 0.5 # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5 # sqrt(4)
dot = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine12 = dot / (len_a * len_b)
s12 = "{:0.2%}".format(cosine12)
```

In [76]:

```
nw=[u'Обычно',u'диссертация',u'включает',u'разделов',u'10',u'Содержание',u'ннотация',u'Введение',u'Постановка',u'задачи',u'Обзор',u'известных',u'методов',u'и',u'средств',u'решения',u'проблемы',u'Исследование',u'и',u'построение',u'решения',u'Описание',u'практической',u'части',u'Заключение',u'Список',u'цитируемой',u'литературы',u'и',u'Приложение']
org=[u'Как',u'правило',u'диссертация',u'включает',u'разделов',u'10',u'Содержание',u'ннотация',u'Введение',u'Постановка',u'задачи',u'Обзор',u'известных',u'методов',u'и',u'средств',u'решения',u'проблемы',u'Исследование',u'и',u'построение',u'решения',u'Описание',u'практической',u'части',u'Заключение',u'Список',u'цитируемой',u'литературы',u'и',u'Приложение']
a_nw = Counter(nw) # int 1 #
b_nw = Counter(org)
words = list(a_nw.keys() | b_nw.keys())
a_vect = [a_nw.get(word, 0) for word in words] # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]
len_a = sum(av*av for av in a_vect) ** 0.5 # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5 # sqrt(4)
dot = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine1 = dot / (len_a * len_b)
s1 = "{:0.2%}".format(cosine1)
```

In [77]:

```
nw=[u'Магистерская',u'диссертация',u'является',u'представлен',u'выпускной',u'квалификационной',u'самостоятельно',u'выполненной',u'научно-прикладной работой',u'по',u'актуальной',u'сайта',u'теме',u'в',u'области',u'информационных',u'технологий']
org=[u'Основная',u'цель',u'Магистерская',u'диссертация',u'закключается',u'обобщении',u'результатов',u'выполненной',u'практическому использованию',u'по',u'области',u'информационных',u'технологий']
a_nw = Counter(nw) # int 2 .Основная цель магистерской диссертации заключается в обобщении работы и предложений по их практическому использованию.
b_nw = Counter(org)
words = list(a_nw.keys() | b_nw.keys())
a_vect = [a_nw.get(word, 0) for word in words] # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]
len_a = sum(av*av for av in a_vect) ** 0.5 # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5 # sqrt(4)
dot = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine2 = dot / (len_a * len_b)
s2 = "{:0.2%}".format(cosine2)
```

In [78]:

```
nw=[u'Магистерская',u'диссертация',u'должна',u'демонстрировать',u'получение',u'магистром',u'углубленных',u'теоретических',u'и',u'умений',u'приобретение',u'необходимых',u'личностных']
org=[u'Магистерская',u'диссертация',u'должна',u'демонстрировать',u'получение',u'магистром',u'углубленных',u'теоретических',u'и',u'умений',u'производственно-технологическая']
```

```

a_nw = Counter(nw) # инт 3
b_nw = Counter(org)
words = list(a_nw.keys() | b_nw.keys())
a_vect = [a_nw.get(word, 0) for word in words] # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]
len_a = sum(av*av for av in a_vect) ** 0.5 # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5 # sqrt(4)
dot = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine3 = dot / (len_a * len_b)
s3 = "{:0.2%}".format(cosine3)

```

In [93]:

```

nw=[u'Магистерская',u'диссертация',u'должна',u'демонстрировать',u'получение',u'магистром',u'углубленных',u'теоретических',
u'и',u'умений',u'приобретение',u'необходимых',u'личностных']
org=[u'Магистерская',u'диссертация',u'должна',u'демонстрировать',u'собой',u'пояснительную',u'записку',u'включающую',u'и',u'
умений',u'последовательность',u'составных',u'частей',u'магистерской']
a_nw = Counter(nw) # инт 4 /
b_nw = Counter(org)
words = list(a_nw.keys() | b_nw.keys())
a_vect = [a_nw.get(word, 0) for word in words] # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]
len_a = sum(av*av for av in a_vect) ** 0.5 # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5 # sqrt(4)
dot = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine4 = dot / (len_a * len_b)
s4 = "{:0.2%}".format(cosine4)

```

In [80]:

```

nw=[u'Образец',u'титульного',u'листа',u'представлен',u'в',u'формате',u'MS',u'Word',u'можно',u'скачать',u'с',u'сайта',u'магистрату
ры',u'(Титульный лист.doc.)']
org=[u'Образец',u'титульного',u'листа',u'представлен',u'в',u'приложение',u'1.',u'Титульный',u'лист',u'в',u'формате',u'MS'
,u'Word',u'можно',u'скачать',u'с',u'сайта',u'магистратуры',u'(Титульный лист.doc.)']
a_nw = Counter(nw) # инт 5
b_nw = Counter(org)
words = list(a_nw.keys() | b_nw.keys())
a_vect = [a_nw.get(word, 0) for word in words] # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]
len_a = sum(av*av for av in a_vect) ** 0.5 # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5 # sqrt(4)
dot = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine5 = dot / (len_a * len_b)
s5 = "{:0.2%}".format(cosine5)

```

In [81]:

```

nw=[u'не',u'более',u'половины
',u'страницы',u'в',u'содержит',u'краткое',u'описани',u'поставленной',u'проблемы',u'методов',u'ее',u'решения',u'и',u'основных'
',u'результатов',u'диссертации']
org=[u'содержит',u'краткое',u'описани',u'поставленной',u'проблемы',u'методов',u'ее',u'решения',u'и',u'основных',u'результатов',u'
'диссертации']
a_nw = Counter(nw) # инт 6
b_nw = Counter(org)
words = list(a_nw.keys() | b_nw.keys())
a_vect = [a_nw.get(word, 0) for word in words] # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]
len_a = sum(av*av for av in a_vect) ** 0.5 # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5 # sqrt(4)
dot = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine6 = dot / (len_a * len_b)
s6 = "{:0.2%}".format(cosine6)

```

In [82]:

```

nw=[u'Список',u'составных',u'частей',u'магистерской',u'диссертации',u'возможно',u'выраженный',u'в',u'терминологи',u'темы',u'с
',u'конкретной',u'магистратуры',u'диссертации']

```

```

org=[u'Список',u'составных',u'частей',u'магистерской',u'диссертации',u'возможно',u'выраженный',u'в',u'терминологи',u'темы',u'с
',u'конкретной',u'диссертации']
a_nw = Counter(nw) # инт 7
b_nw = Counter(org)
words = list(a_nw.keys() | b_nw.keys())
a_vect = [a_nw.get(word, 0) for word in words] # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]
len_a = sum(av*av for av in a_vect) ** 0.5 # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5 # sqrt(4)
dot = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine7 = dot / (len_a * len_b)
s7 = "{:0.2%}".format(cosine7)

```

In [83]:

```

nw=[u'должно',u'кратко',u'описывать',u'содержательном',u'на',u'уровне',u'предметную',u'область',u'можно',u'к',u'которой',u'отно
сится',u'тема',u'магистерской',u'диссертации']
org=[u'Образец',u'титального',u'листа',u'представлен',u'в',u'приложение',u'1.',u'Титульный',u'лист',u'в',u'формате',u'MS'
,u'Word',u'можно',u'скачать',u'с',u'сайта',u'магистратуры',u'(Титульный лист.doc).']
a_nw = Counter(nw) #инт 8
b_nw = Counter(org)
words = list(a_nw.keys() | b_nw.keys())
a_vect = [a_nw.get(word, 0) for word in words] # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]
len_a = sum(av*av for av in a_vect) ** 0.5 # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5 # sqrt(4)
dot = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine8 = dot / (len_a * len_b)
s8 = "{:0.2%}".format(cosine8)

```

In [84]:

```

nw=[u'Должна',u'содержать',u'описание',u'некоторой',u'в',u'проблемы',u'в',u'рассматриваемой',u'предметной',u'области',u'с',u'об
основание',u'актуальности',u'решения',u'этой',u'проблемы',u'определение',u'требований',u'к',u'магистерской',u'диссертации']
org=[u'Должна',u'содержать',u'описание',u'некоторой',u'в',u'проблемы',u'в',u'рассматриваемой',u'предметной',u'области',u'с',u'об
основание',u'актуальности',u'решения',u'этой',u'проблемы.']
a_nw = Counter(nw) # инт 9
b_nw = Counter(org)
words = list(a_nw.keys() | b_nw.keys())
a_vect = [a_nw.get(word, 0) for word in words] # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]
len_a = sum(av*av for av in a_vect) ** 0.5 # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5 # sqrt(4)
dot = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine9 = dot / (len_a * len_b)
s9 = "{:0.2%}".format(cosine9)

```

In [85]:

```

nw=[u'В',u'ней',u'также',u'описываются',u'показатели',u'для',u'количественной',u'или',u'совершенствуются',u'области',u'с',u'об
снование',u'актуальности',u'решения',u'этой',u'проблемы',u'определение',u'требований',u'к',u'магистерской',u'диссертации']
org=[u'В',u'ней',u'также',u'описываются',u'показатели',u'для',u'количественной',u'или',u'совершенствуются',u'методологии',u'с',
u'модели',u'методы',u'средства',u'алгоритмы',u'к',u'магистерской',u'диссертации']
a_nw = Counter(nw) # инт 10 В ней также описываются показатели для количественной или совершенствуются:
методологии, модели, методы, средства, алгоритмы, программные
b_nw = Counter(org)
words = list(a_nw.keys() | b_nw.keys())
a_vect = [a_nw.get(word, 0) for word in words] # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]
len_a = sum(av*av for av in a_vect) ** 0.5 # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5 # sqrt(4)
dot = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine10 = dot / (len_a * len_b)
s10 = "{:0.2%}".format(cosine10)

```

In [86]:


```

nw=[u'Содержит',u'материал',u'прикладного',u'характера',u'подтверждающий',u'возможность',u'с',u'реализации',u'сценария',u'решения',u'функционирования',u'проблемы',u'определение',u'требований',u'к',u'магистерской',u'диссертации']
org=[u'Содержит',u'материал',u'прикладного',u'характера',u'подтверждающий',u'возможность',u'среды',u'описание',u'можно',u'сценария',u'с',u'функционирования',u'магистратуры',u'диссертации.]
a_nw = Counter(nw) # инт 11
b_nw = Counter(org)
words = list(a_nw.keys() | b_nw.keys())
a_vect = [a_nw.get(word, 0) for word in words] # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]
len_a = sum(av*av for av in a_vect) ** 0.5 # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5 # sqrt(4)
dot = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine11 = dot / (len_a * len_b)
s11 = "{:0.2%}".format(cosine11)

```

In [87]:

```

nw=[u'Должна',u'содержать',u'краткий',u'обзор',u'основных',u'теоретических',u'и',u'прикладных',u'результатов',u'магистерской',u'диссертации']
org=[u'Должна',u'содержать',u'краткий',u'обзор',u'основных',u'теоретических',u'и',u'прикладных',u'результатов',u'ВКР']
a_nw = Counter(nw) # инт 13/ должно содержать краткий обзор основных теоретических и прикладных результатов магистерской диссертации, выносимых на защиту и согласованных с целями и задачами магистерской диссертации.
b_nw = Counter(org)
words = list(a_nw.keys() | b_nw.keys())
a_vect = [a_nw.get(word, 0) for word in words] # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]
len_a = sum(av*av for av in a_vect) ** 0.5 # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5 # sqrt(4)
dot = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine13 = dot / (len_a * len_b)
s13 = "{:0.2%}".format(cosine13)

```

In [88]:

```

nw=[u'Должна',u'содержать',u'не',u'менее',u'30-40',u'источников',u'по',u'теме',u'исследования',u'расположенных',u'в',u'порядке',u'появления']
org=[u'Образец',u'Должна',u'содержать',u'не',u'менее',u'30-40',u'источников',u'по',u'теме',u'исследования',u'расположенных',u'в',u'порядке',u'появления',u'ссылоч.]
a_nw = Counter(nw) # инт 14
b_nw = Counter(org)
words = list(a_nw.keys() | b_nw.keys())
a_vect = [a_nw.get(word, 0) for word in words] # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]
len_a = sum(av*av for av in a_vect) ** 0.5 # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5 # sqrt(4)
dot = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine14 = dot / (len_a * len_b)
s14 = "{:0.2%}".format(cosine14)

```

In [89]:

```

nw=[u'Образец',u'Магистерская',u'диссертация',u'на',u'защите',u'оценивается',u'исходя',u'из',u'степени',u'в',u'выполнения',u'студентом',u'вышеперечисленных',u'требований',u'к',u'содержанию',u'а',u'магистратуры',u'качества']
org=[u'Магистерская',u'диссертация',u'на',u'защите',u'оценивается',u'исходя',u'из',u'степени',u'в',u'выполнения',u'студентом',u'вышеперечисленных',u'требований',u'к',u'содержанию',u'а',u'магистратуры']
a_nw = Counter(nw) # инт 15
b_nw = Counter(org)
words = list(a_nw.keys() | b_nw.keys())
a_vect = [a_nw.get(word, 0) for word in words] # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]
len_a = sum(av*av for av in a_vect) ** 0.5 # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5 # sqrt(4)
dot = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine15 = dot / (len_a * len_b)

```

```
s15 = "{:0.2%}".format(cosine15)
```

In [90]:

```
nw=[u'Магистерская',u'диссертация',u'на',u'защите',u'оценивается',u'исходя',u'из',u'степени',u'в',u'выполнения',u'студентом',u'вышеперечисленных',u'требований',u'к',u'содержанию',u'а',u'магистратуры',u'качества']
org=[u'Магистерская',u'диссертация',u'на',u'защите',u'оценивается',u'исходя',u'из',u'степени',u'в',u'выполнения',u'студентом',u'вышеперечисленных',u'требований',u'к',u'содержанию',u'а',u'качества',u'оформления',u'магистратуры',u'диссертации']
a_nw = Counter(nw) # инт 16 Магистерская диссертация на защите оценивается, исходя из степени выполнения студентом вышеперечисленных требований к содержанию, а также с учетом качества оформления магистерской диссертации.
b_nw = Counter(org)
words = list(a_nw.keys() | b_nw.keys())
a_vect = [a_nw.get(word, 0) for word in words] # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]
len_a = sum(av*av for av in a_vect) ** 0.5 # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5 # sqrt(4)
dot = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine16 = dot / (len_a * len_b)
s16= "{:0.2%}".format(cosine16)
```

In [92]:

```
data = [['Intent_1', cosine1,s1],
        ['Intent_2', cosine2,s2],
        ['Intent_3', cosine3,s3],
        ['Intent_4', cosine4,s4],
        ['Intent_5', cosine5,s5],
        ['Intent_6', cosine6,s6],
        ['Intent_7', cosine7,s7],
        ['Intent_8', cosine8,s8],
        ['Intent_9', cosine9,s9],
        ['Intent_10', cosine10,s10],
        ['Intent_11', cosine11,s11],
        ['Intent_12', cosine12,s12],
        ['Intent_13', cosine13,s13],
        ['Intent_14', cosine14,s14],
        ['Intent_15', cosine15,s15],
        ['Intent_16', cosine16,s16]]
df = pd.DataFrame(data, columns = ['Intent', 'Coeff','Percent'])
df.sort_values(by=['Coeff', 'Percent'], inplace=True)
df.style.background_gradient(cmap='YlGnBu')
```

Out[92]:

	Intent	Coeff	Percent
0	Intent_1	0.955330	95.53%
1	Intent_2	0.470871	47.09%
2	Intent_3	0.836242	83.62%
3	Intent_4	0.296500	29.65%
4	Intent_5	0.816497	81.65%

	Intent	Coeff	Percent
5	Intent_6	0.840168	84.02%
6	Intent_7	0.968246	96.82%
7	Intent_8	0.056344	5.63%
8	Intent_9	0.801388	80.14%
9	Intent_10	0.668648	66.86%
10	Intent_11	0.518563	51.86%
11	Intent_12	0.816497	81.65%
12	Intent_13	0.858116	85.81%
13	Intent_14	0.930949	93.09%
14	Intent_15	0.945905	94.59%
15	Intent_16	0.948683	94.87%

Метод HTTP и URL: в приложение 1

POST https://REGION_ID-dialogflow.googleapis.com/v3/projects/PROJECT_ID/locations/REGION_ID/agents/AGENT_ID/sessions/SESSION_ID:detectIntent

Тело запроса JSON:

```
{
  "queryInput": {
    "text": {
      "text": "END_USER_INPUT"
    },
    "languageCode": "en"
  },
  "queryParams": {
    "timeZone": "America/Los_Angeles"
  }
}
```

Чтобы отправить запрос, разверните один из следующих вариантов:

curl (Linux, macOS или Cloud Shell)

PowerShell (Windows)

Вы должны получить ответ JSON, подобный следующему:

```
{
  "responseId": "38e8f23d-eed2-445e-a3e7-149b242dd669",
  "queryResult": {
    "text": "I want to buy a shirt",
    "languageCode": "en",
    "responseMessages": [
      {
        "text": {
          "text": [
            "Ok, let's start a new order."
          ]
        }
      },
      {
        "text": {
          "text": [
            "I'd like to collect a bit more information from you."
          ]
        }
      },
      {
        "text": {
          "text": [
            "What color would you like?"
          ]
        }
      }
    ],
    "currentPage": {
      "name": "projects/PROJECT_ID/locations/us-central1/agents/133b0350-f2d2-4928-b0b3-5b332259d0f7/flows/00000000-0000-0000-000000000000/pages/ce0b88c4-9292-455c-9c59-ec153dad94cc",
      "displayName": "New Order"
    },
    "intent": {
      "name": "projects/PROJECT_ID/locations/us-central1/agents/133b0350-f2d2-4928-b0b3-5b332259d0f7/intents/0adebb70-a727-4687-b8bc-fbbc2ac0b665",
      "displayName": "order.new"
    },
    "intentDetectionConfidence": 1,
    "diagnosticInfo": { ... },
    "match": {
```

```

    "intent": {
      "name": "projects/PROJECT_ID/locations/us-central1/agents/133b0350-f2d2-4928-b0b3-5b332259d0f7/intents/0adebb70-a727-4687-b8bc-fbbc2ac0b665",
      "displayName": "order.new"
    },
    "resolvedInput": "I want to buy a shirt",
    "matchType": "INTENT",
    "confidence": 1
  }
}
}

```

косинусное сходство (2). Код программы приведен в Приложении 3.

```

from collections import Counter
import pandas as pd

nw=[u'Образец',u'титального',u'листа',u'представлен',u'в',u'формате',u'MS',u'Word'
,u'можно',u'скачать',u'с',u'сайта',u'магистратуры',u'(Титульный лист.doc.)']
org=[u'Образец' ,u'титального' ,u'листа' ,u'представлен' ,u'в' ,u'приложение' ,u'1.'
,u'Титульный' ,u'лист' ,u'в' ,u'формате' ,u'MS' ,u'Word' ,u'можно' ,u'скачать' ,u'с'
,u'сайта' ,u'магистратуры' ,u'(Титульный лист.doc ).']

a_nw = Counter(nw) # инт 12 кор мекна
b_nw = Counter(org)

words = list(a_nw.keys() | b_nw.keys())

a_vect = [a_nw.get(word, 0) for word in words]      # [0, 0, 1, 1, 2, 1]
b_vect = [b_nw.get(word, 0) for word in words]

len_a = sum(av*av for av in a_vect) ** 0.5        # sqrt(7)
len_b = sum(bv*bv for bv in b_vect) ** 0.5        # sqrt(4)
dot   = sum(av*bv for av,bv in zip(a_vect, b_vect)) # 3
cosine12 = dot / (len_a * len_b)
s12 = "{:0.2%}".format(cosine12)

```