

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
федеральное государственное бюджетное образовательное учреждение высшего образования
«Тольяттинский государственный университет»

Кафедра «Прикладная математика и информатика»
(наименование)

09.04.03 Прикладная информатика
(код и наименование направления подготовки)

Управление корпоративными информационными процессами
(направленность (профиль))

ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА (МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ)

на тему «Исследование эффективности использования машинного обучения для обработки входящих запросов в helpdesk-подразделениях крупных ИТ-компаний»

Обучающийся

А.А. Корнишин
(Инициалы Фамилия)

(личная подпись)

Научный
руководитель

канд.пед.наук, доцент О.М. Гущина

(ученая степень (при наличии), ученое звание (при наличии), Инициалы Фамилия)

Тольятти 2024

Содержание

Введение.....	3
1 Принципы работы helpdesk-систем и применение методов машинного обучения.....	7
1.1 Принципы функционирования Helpdesk-систем.....	7
1.2 Сложности во взаимодействии и возможные решения с помощью машинного обучения.....	9
1.3 Бизнес-моделирование и анализ ценности.....	12
1.4 Сбор и отбор научных материалов.....	18
1.5 Применение машинного обучения в задачах классификации и обработки запросов: анализ научных исследований.....	20
2 Анализ технологий машинного обучения.....	23
2.1 Методы классификации текстовых запросов.....	23
2.2 Методы машинного обучения для классификации текстовых запросов.....	26
2.3 Обзор существующих решений.....	27
2.4 Моделирование бизнес-процесса «Как есть».....	34
2.5 Анализ методов обработки входящих запросов.....	38
2.6 Моделирование бизнес-процесса «Как должно быть».....	39
2.7 Альтернативные решения для автоматизации.....	41
2.8 Основные бизнес-цели и объем проекта.....	44
3 Практическое исследование эффективности использования машинного обучения для обработки входящих запросов.....	48
3.1 Тестирование решения.....	52
3.2 Проведение эксперимента.....	56
3.3 Апробация решения.....	58
3.4 Результаты апробации.....	60
Заключение.....	67
Список используемой литературы.....	69

Введение

Современные IT-компании предлагают разнообразные услуги, что делает необходимой обработку большого числа разных запросов, поступающих в подразделения helpdesk. Вопросы по их классификации, приоритетам и распределению возлагаются на первую линию службы поддержки. В большинстве случаев это значительно повышает нагрузку на данную службу и, как следствие, возрастают затраты на её содержание. Данное исследование актуально в свете потребности в эффективной системе, которая автоматически могла бы направлять запросы нужным специалистам и классифицировать их. На данный момент отсутствует единый метод или алгоритм, который мог бы оптимизировать работу любого helpdesk подразделения.

Суть проблемы — в поиске оптимального способа обработки и классификации входящих запросов, который бы не только ускорял и улучшал распределение, но и сводил к минимуму участие сотрудников на начальных этапах. Настоящее исследование предполагает анализ различных существующих моделей машинного обучения и оценку их эффективности в реальной работе helpdesk-подразделения. Таким образом, целью работы становится доказательство целесообразности применения машинного обучения в службах технической поддержки.

Объектом исследования выступает процесс обработки входящих запросов в helpdesk-подразделении.

Предмет исследования — использование машинного обучения для автоматической классификации, приоритезации и распределения запросов.

Гипотеза исследования заключается в том, что применение алгоритмов машинного обучения оптимизирует обработку входящих сообщений в helpdesk-подразделении.

Для достижения цели исследования были поставлены следующие задачи:

- изучить существующие научные подходы и практические методики использования машинного обучения;
- определить актуальные алгоритмы машинного обучения и провести их сравнительный анализ;
- провести апробацию с целью оценки точности, скорости и эффективности выбранного решения.

Теоретическую основу данного исследования составляют работы таких российских и зарубежных авторов, как Барахнин В.Б. [4], Батура Т.В. [5], Большакова Е.И. [6], Варшавский П.Р. [7], Кашницкий Ю.С. [11], а также Jun S. и Park S.S. [37]. Эти авторы внесли значительный вклад в развитие теории и практики обработки текстовых данных и автоматической классификации. В их работах изложены как основные принципы обработки текстов, такие как токенизация, лемматизация и извлечение признаков, так и специальные подходы к обучению моделей машинного обучения, включая классификаторы Naïve Bayes, метод опорных векторов и ансамблевые методы, такие как градиентный бустинг [35].

Работы отечественных авторов часто фокусируются на адаптации методов обработки текстов к особенностям русского языка, предлагая подходы к решению проблем морфологического анализа, многозначности слов и специфики синтаксиса. В исследованиях таких авторов, как Большакова Е.И. и Варшавский П.Р., подробно рассматриваются алгоритмы для извлечения и классификации текстов на русском языке, что помогает более точно настраивать модели для специфических задач, таких как распределение запросов.

Исследования зарубежных авторов, таких как Jun S. и Park S.S., в свою очередь, акцентируют внимание на создании более общих и универсальных моделей, применимых к текстам. Чаще всего, сходятся в идее использования глубоких нейронных сетей и методов представления слов, таких как Word2Vec и BERT, которые позволяют моделям замечать контекстные

зависимости, что является важным элементом для эффективной классификации и распределения запросов.

На сегодняшний день сфера применения машинного обучения для обработки входящих запросов достаточно хорошо изучена, проведено значительное количество исследований и объем достижений высок. Основные направления уже освещены, однако, что касается практической реализации в различных условиях (например, в крупных IT-компаниях), требуется анализ и адаптация.

Методологической основой исследования являются принципы системного анализа, которые позволяют рассматривать процесс обработки запросов как неотъемлемую часть общей информационной системы компании. Применение методов машинного обучения, включая классификацию с использованием алгоритмов Naive Bayes и SVM, а также обработку естественного языка (NLP) с использованием моделей BERT и Word2Vec, обеспечивает структурированный подход к анализу текстовых данных.

В рамках исследования используются методология структурного подхода к анализу и проектированию, системный анализ и синтез, объектно-ориентированный анализ и проектирование. Эти подходы подкреплены применением методов моделирования и инструментов визуализации, включая UML и CASE-технологии для структурного и объектно-ориентированного проектирования. Они обеспечивают формализацию требований и описание процессов обработки запросов.

Исследование проводилось в несколько этапов - от анализа и выбора подходящих алгоритмов, до экспериментальной проверки решения.

На защиту выносятся:

- разработанная модель машинного обучения позволяет автоматизировать классификацию входящих запросов с высокой точностью;

- применение предложенного подхода приводит к оптимизации операционных затрат и повышению качества обслуживания клиентов.

Новизна данного исследования заключается в оригинальном применении совокупности методов машинного обучения для оптимизации процесса обработки входящих запросов в helpdesk подразделения.

Практическая значимость работы состоит в возможности внедрения разработанного решения оптимизации работы helpdesk подразделения. Научная значимость работы заключается в разработке и оценке подходов к автоматической классификации текстовых запросов, что расширяет методологическую базу для анализа и обработки слабоструктурированных данных. Исследование вносит вклад в повышение точности и скорости обработки заявок, что может стать основой для более эффективных систем поддержки.

Объем и структура диссертации: исследование состоит из введения, трех разделов, заключения и библиографии. Работа изложена на 73 страницах, содержит 23 рисунка и 8 таблиц.

1 Принципы работы helpdesk-систем и применение методов машинного обучения

1.1 Принципы функционирования Helpdesk-систем

Системы учета и обработки заявок, такие как Helpdesk, стали ключевым элементом автоматизации процессов поддержки клиентов и обеспечения сопровождения ИТ-услуг внутри организаций. Появившись более двух десятилетий назад, эти системы сыграли важную роль в развитии сервисного подхода к управлению ИТ, способствуя повышению эффективности взаимодействия с пользователями и оптимизации внутренних процессов компаний [10][37]. Они предназначены для управления и решения проблем пользователей в области информационных технологий и не только. Вот несколько основных принципов и функциональных аспектов, которые обычно присутствуют в helpdesk системах:

- основной принцип helpdesk системы – это учет и обработка заявок пользователей. Каждая проблема или запрос регистрируется как новая заявка и отслеживается с момента поступления до закрытия.;
- возможность приоритезации заявок в зависимости от сроков их решения;
- инструменты для мониторинга и отслеживания статусов заявок для возможности следить за процессом их решения;
- обработка запросов и учет трудозатрат. Реализация функционала по обработке запросов и учету времени, затраченного на выполнение задач;
- управление задачами и коллективной работой над проектами, реализация функционала управления задачами и кооперативной деятельностью в рамках проектов;
- уведомления и отчеты;
- интеграция с другими системами и инструментами.

Классически бизнес-процесс обработки входящего запроса технической поддержкой выглядит следующим образом: клиент обращается в техническую поддержку, оператор принимает несколько решений по идентификации и классификации запроса, создает заявку, передает её на исполнении, после выполнения заявки информирует об этом клиента и закрывает заявку, в соответствии с рисунком 1.

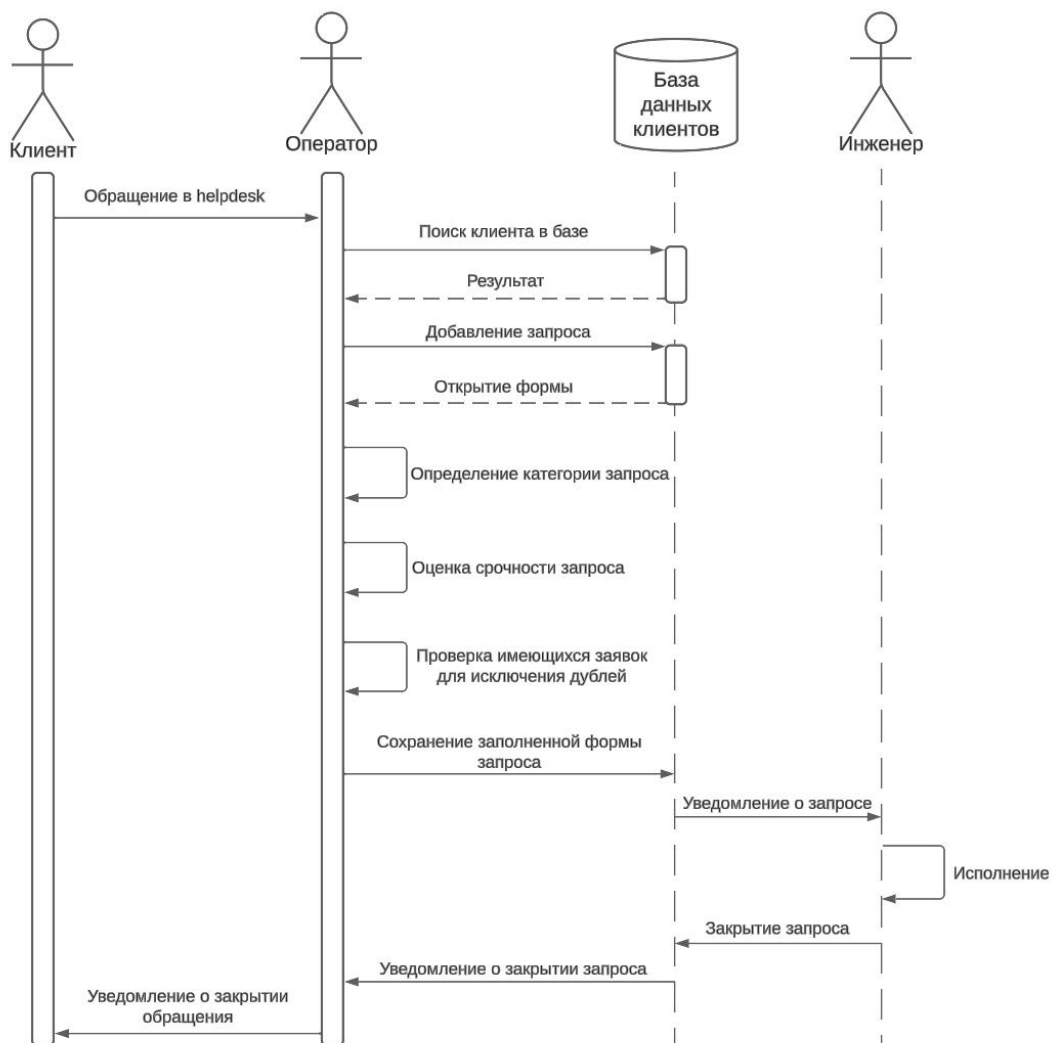


Рисунок 1 – Диаграмма последовательности обработки входящих запросов

1-я линия техподдержки компании тратит много времени на принятия решений при регистрации заявок от пользователей и маршрутизацию запросов в другие отделы. Внедрение методов машинного обучения направлено на

упрощение операций 1-й линии, осуществляющей обработку заявок. Внедрение информационной системы (ИС) нацелены на достижение следующих целей:

Во-первых, оптимизация времени обработки запросов. Внедрение технологий машинного обучения предоставляет возможность автоматизации и эффективной оптимизации процессов, что приводит к сокращению времени, требуемого для решения входящих запросов [20].

Кроме того, снижение частоты повторных запросов. Система, обученная на основе исторических данных, способна предсказывать и эффективно решать типовые проблемы, снижая вероятность повторных обращений со стороны клиентов.

И, в-третьих – структурирование логики последовательности действий. Интеграция методов машинного обучения предоставляет возможность улучшения логики и последовательности действий 1-й линии при обработке запросов. Модель может предоставлять рекомендации относительно оптимальных шагов для решения конкретных проблем.

1.2 Сложности во взаимодействии и возможные решения с помощью машинного обучения

В ходе взаимодействия между клиентами, операторами helpdesk и инженерами неизбежно возникают различные проблемы, которые влияют на эффективность работы helpdesk-подразделения. В представленной ниже таблице 1 описаны типичные ситуации, с которыми сталкиваются helpdesk-подразделения при обработке поступающих запросов. Для каждой ситуации был проведен анализ с точки зрения влияния на процессы поддержки и обслуживания и предложены возможные варианты решения, в том числе, и с использованием современных методов машинного обучения.

Таблица 1 – Сложности при обработке заявок и варианты решения

Сложность	Варианты решения	Варианты решения с помощью машинного обучения
Задержки в обработке запросов	внедрение системы приоритизации запросов на основе их срочности и важности	прогнозирование времени обработки запроса, разработка системы машинного обучения для прогнозирования времени, необходимого для обработки конкретного запроса, основываясь на типе проблемы, его приоритете и других факторах
	обучение сотрудников более эффективным методам работы и использование автоматизированных инструментов	
Низкая эффективность решения проблем	регулярные обновления базы знаний и обучение персонала новым методам решения типовых проблем	автоматизация процесса решения типовых проблем предполагает применение алгоритмов для автоматического распознавания и обработки стандартных запросов, это позволит значительно снизить нагрузку на персонал и повысить общую эффективность работы системы технической поддержки
	внедрение системы мониторинга для предотвращения повторных запросов по одной и той же проблеме	
Неудовлетворенность клиентов	проведение опросов удовлетворенности клиентов и анализ обратной связи для улучшения процессов и услуг	предсказание удовлетворенности клиентов; разработка моделей анализа настроений и удовлетворенности клиентов на основе их запросов и обратной связи для быстрого выявления проблемных ситуаций
	внедрение системы обратной связи и уведомлений о статусе запроса для улучшения прозрачности	
Отсутствие автоматизации и оптимизации	внедрение современных систем управления запросами и автоматизации рутинных задач	автоматическая категоризация запросов; создание модели классификации, которая автоматически определяет категорию запроса, ускоряя его дальнейшую обработку и направление к соответствующему специалисту.
	регулярное обновление программного обеспечения и технологических инструментов	
Недостаточная квалификация персонала	организация регулярных тренингов и обучающих программ для персонала	оптимизация ресурсов в пиковые периоды; использование алгоритмов машинного обучения для прогнозирования временных периодов повышенной активности и автоматического масштабирования ресурсов helpdesk
	внедрение системы шефства для поддержки и обмена опытом между сотрудниками	

Продолжение таблицы 1

Проблема	Варианты решения	Варианты решения с помощью машинного обучения
Неэффективное использование технологий	анализ эффективности текущих технологических инструментов и их оптимизация	персонализированная поддержка - разработка системы персонализированной поддержки на основе данных о предыдущих запросах пользователя для более точного и быстрого предоставления информации
	обучение персонала новым инструментам	
Проблемы в коммуникации между helpdesk и другими подразделениями компании	введение единой платформы для внутренней коммуникации	идентификация проблем в коммуникации, применение текстовой аналитики для обнаружения коммуникационных проблем на основе анализа запросов клиентов и их обратной связи
	регулярные встречи и обучения по коммуникационным навыкам для персонала	
Большая нагрузка в пиковые периоды	создание гибких графиков работы и временных команд для обработки пиковых нагрузок	автоматизированная система обратной связи - создание системы, которая автоматически отправляет клиентам обратную связь после завершения обработки их запроса, опираясь на анализ качества оказанных услуг
Недостаточная обратная связь	внедрение системы автоматических уведомлений о статусе запроса	выявление аномалий для обеспечения безопасности данных, применение методов обучения с учителем и без учителя для обнаружения нехарактерного поведения или попыток несанкционированного доступа к данным
	введение стандартов об обратной связи и их регулярное обновление	

Однако, несмотря на эти преимущества, важно осознавать ряд вызовов, связанных с внедрением машинного обучения в техническую поддержку [30]. Проблемы могут включать в себя необходимость качественного обучения алгоритмов для минимизации возможных ошибок, а также поддержание баланса между автоматизацией и человеческим вмешательством в сложных и нестандартных сценариях.

Несмотря на выявленные трудности, внедрение машинного обучения позволит создать более эффективные процессы, что, в конечном итоге,

приведет к улучшению уровня обслуживания клиентов и повышению конкурентоспособности на рынке.

1.3 Бизнес-моделирование и анализ ценности

Рассмотрим теоретико-методологические основы бизнес-моделирования, а также ключевые подходы к анализу ценности, создаваемой компанией для своих клиентов. Бизнес-моделирование позволяет структурировать и визуализировать процессы создания и передачи ценности, обеспечивая всесторонний анализ стратегии, операционных механизмов и потребностей целевой аудитории [40].

Модель мотивации бизнеса — это структура, описывающая ключевые элементы, которые мотивируют бизнес к действиям, а также стратегии и тактики, которые компания использует для достижения своих целей. Диаграмма ВММ (Business Motivation Model), в первую очередь, предназначена для отражения мотивации и стратегии организации в целом, а не для детализации конкретных бизнес-процессов. Тем не менее, она может помочь понять и обосновать, почему бизнес-процессы реализуются определенным образом, и как они соотносятся с целями и стратегиями компании. На рисунке 2 показана диаграмма ВММ для процесса внедрения машинного обучения в обработку заявок подразделением helpdesk.

Для анализа и оптимизации всех этапов процесса создания продукта или услуги используется следующий инструмент – Поток создания ценности (Value Stream). Это последовательность всех действий (как добавляющих, так и не добавляющих ценность), необходимых для создания продукта или услуги, начиная с первоначального запроса клиента и заканчивая его удовлетворением. Поток создания ценности охватывает весь цикл производства и поставки, включая проектирование, производство, доставку и послепродажное обслуживание. Анализ этого потока позволяет компаниям

выявлять и устранять потери, оптимизировать процессы и улучшать эффективность.

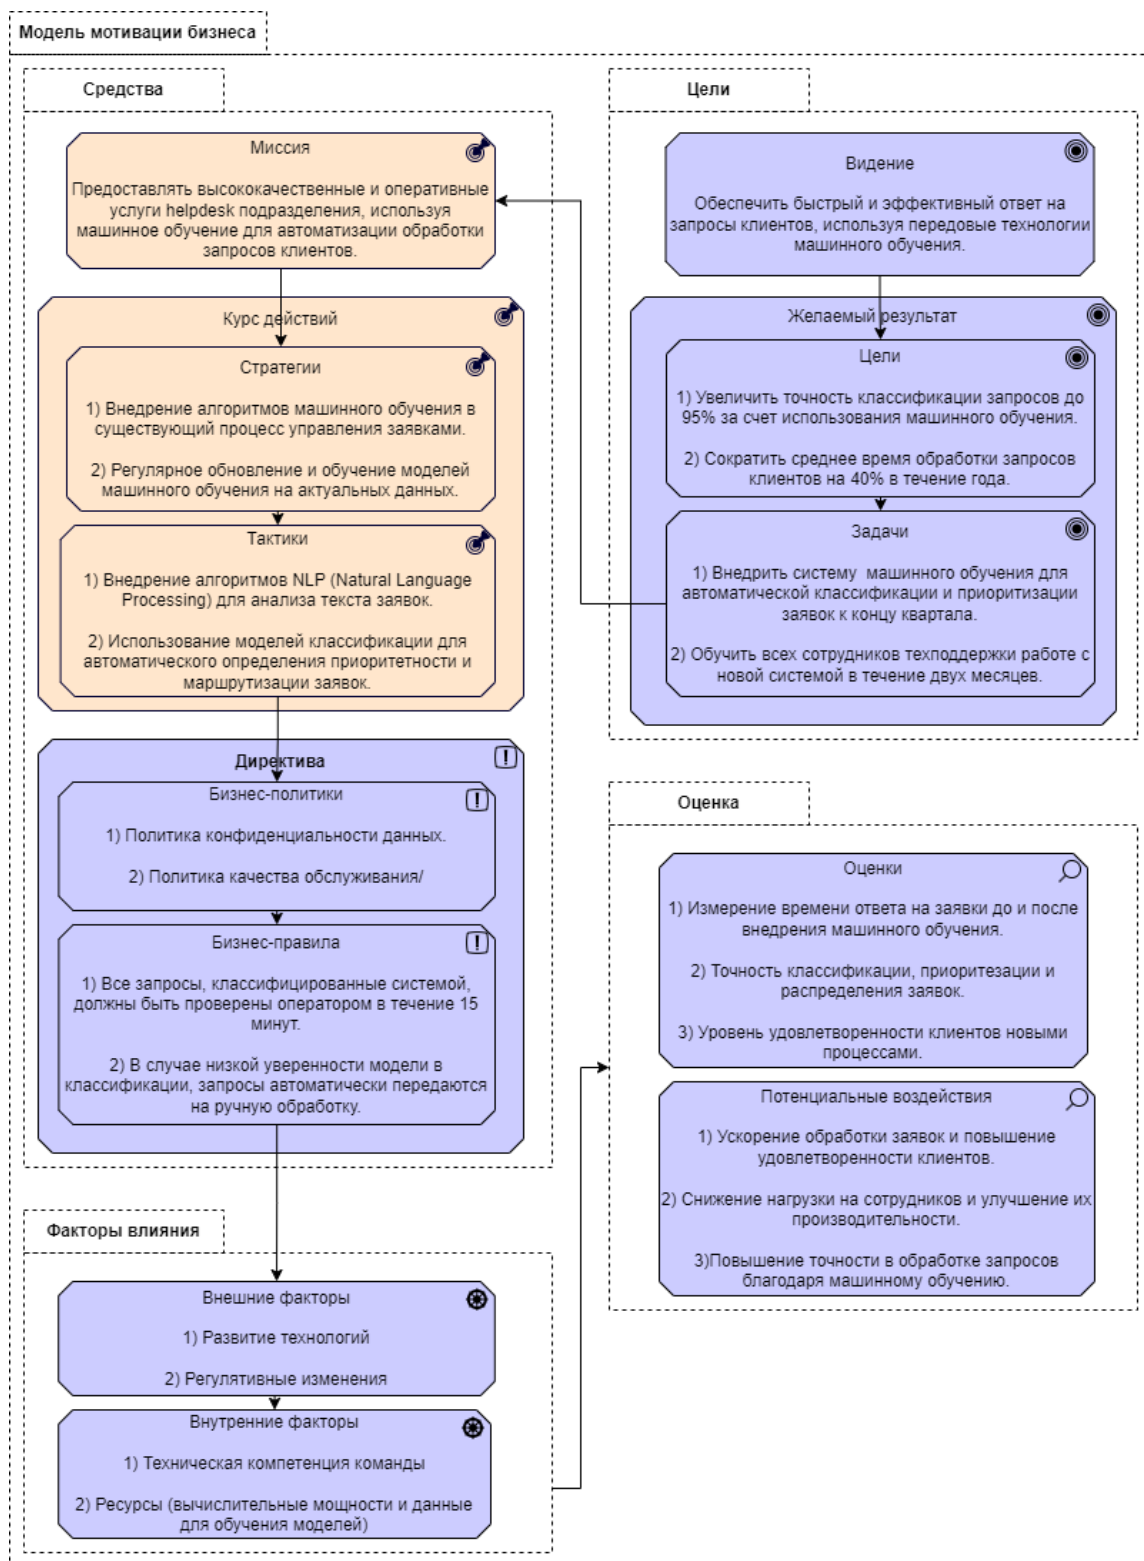


Рисунок 2 - Диаграмма ВММ

На рисунке 3 отображен Поток создания ценности бизнес-процесса по обработке запросов. Поток создания ценности демонстрирует текущее состояние и помогает спроектировать будущее состояние процесса.

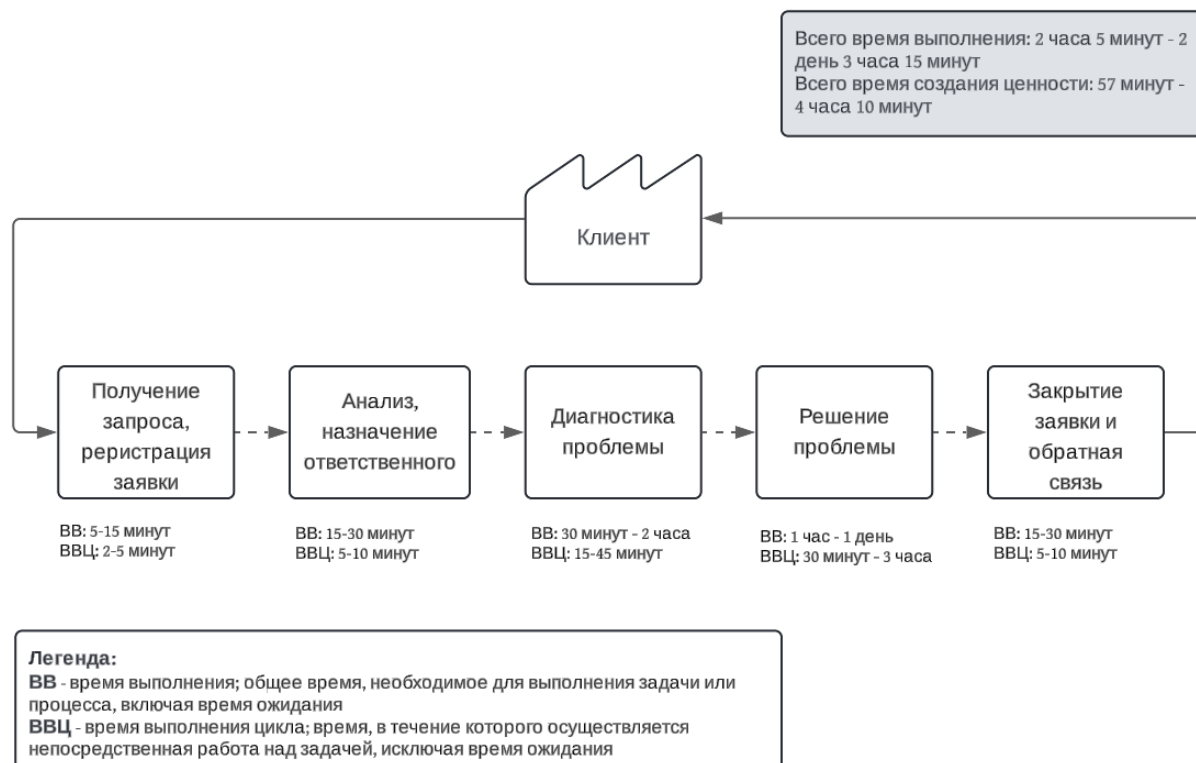


Рисунок 3 – Поток создания ценности

Еще одним инструментом для улучшения и оптимизации бизнес-процессов является Карта пути клиента. Этот инструмент используется для глубокого понимания клиента, выявления проблемных зон и потенциальных точек улучшения качества обслуживания, повышения удовлетворенности клиентов и их лояльности. Визуальное представление всех взаимодействий клиента с компанией, предоставляющей ему товары или услуги, на протяжении всего цикла его взаимоотношений, отражено на рисунке 4. Включает в себя этапы пути клиента, точки контакта, действия, эмоции и болевые точки.

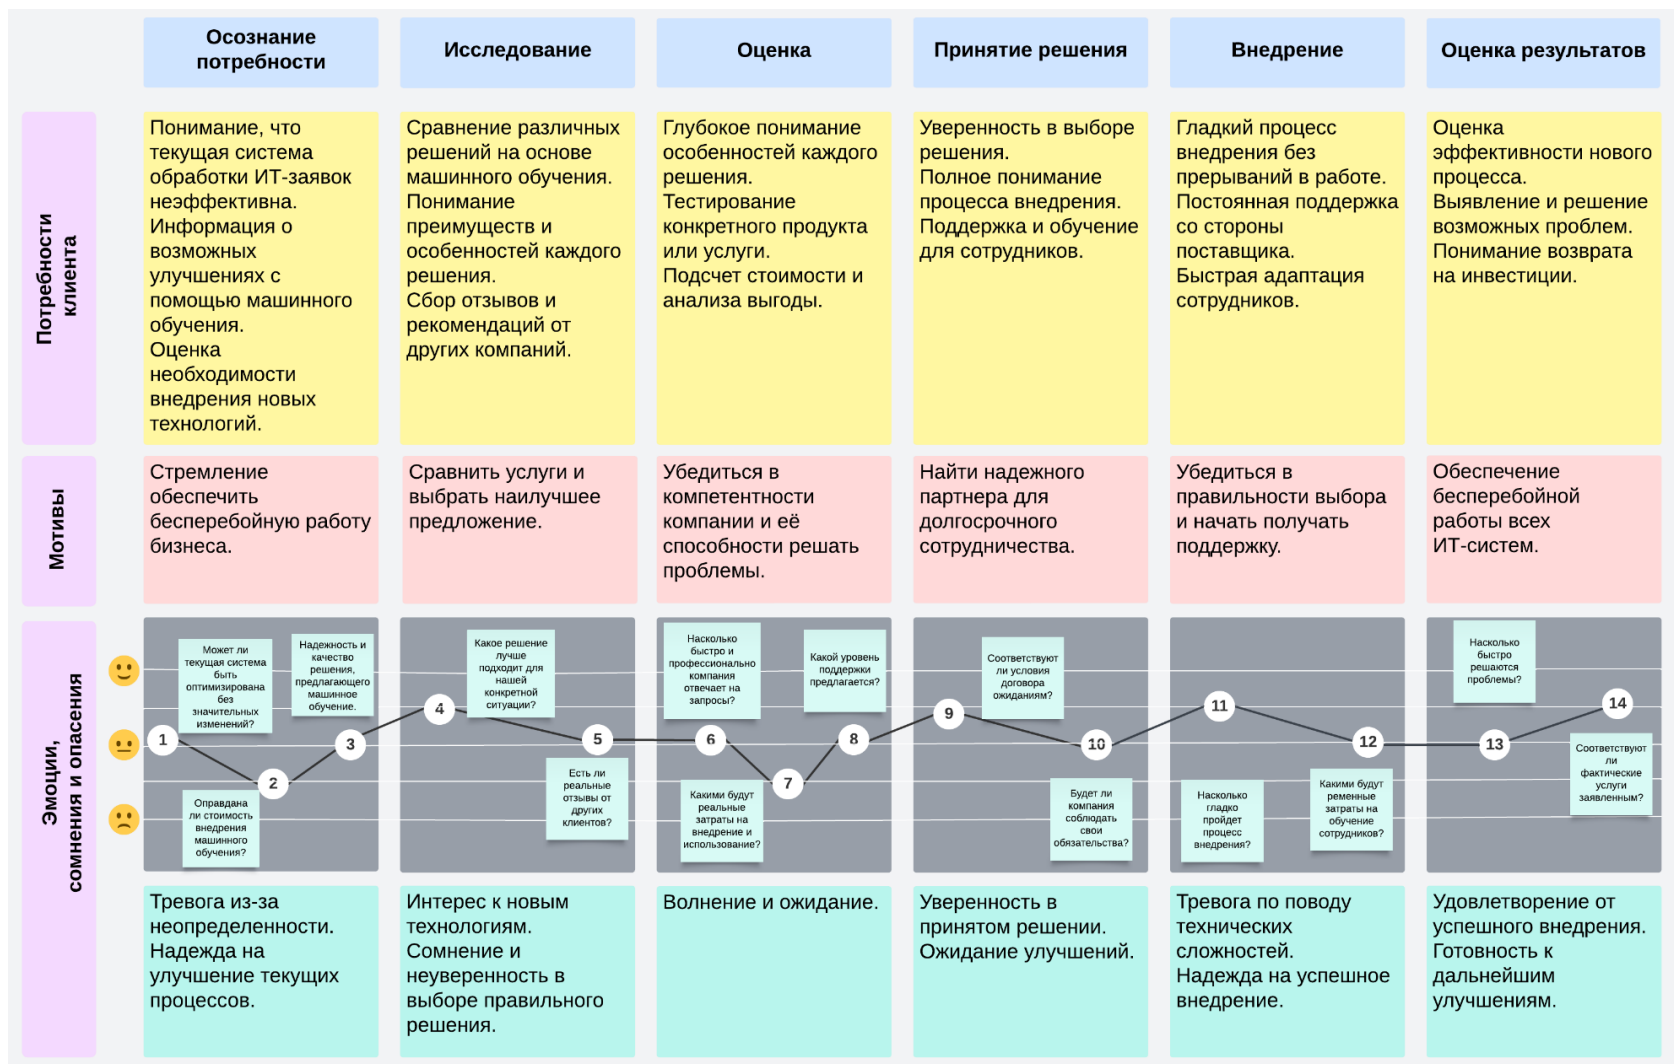


Рисунок 4 – Карта пути клиента

Ценностное предложение сформулировано следующим образом: «Наше решение на базе ИИ обеспечивает автоматизированную обработку запросов, что сокращает время отклика с 6 до 2 часов, снижает количество ошибок в маршрутизации с 20% до 5%, и увеличивает удовлетворенность клиентов с 85% до 95%. Это позволяет вам улучшить производительность вашего helpdesk, оптимизировать операционные затраты и предоставить клиентам лучший опыт обслуживания.»

Чтобы определить ключевые преимущества продукта и факторы влияния на выбор клиента, используем Value Proposition Canvas — шаблон ценностного предложения, разработанный Александром Остервальдером, отраженный на рисунке 5.

Создание Value Proposition (Ценностного предложения) с использованием Value Proposition Canvas подразумевает глубокое понимание потребностей клиента (Customer Profile) и того, как продукт или услуга может их удовлетворить (Value Map). Слева: Customer Profile с задачами, болями и выигрышами, справа: Value Map с продуктами, устраняющими боли и создающими ценность.



Рисунок 5 – Бизнес-план по реализации ценностного предложения

Эта Value Proposition адресует ключевые задачи клиента, устраняет боли и предоставляет реальные выгоды, которые позволяют оптимизировать работу helpdesk-подразделения и повысить конкурентоспособность компании.

Карта эмпатии (рисунок 6) помогает глубже понять потребности, чувства и ожидания пользователей в рамках взаимодействия с ИТ-решениями или бизнес-процессами.

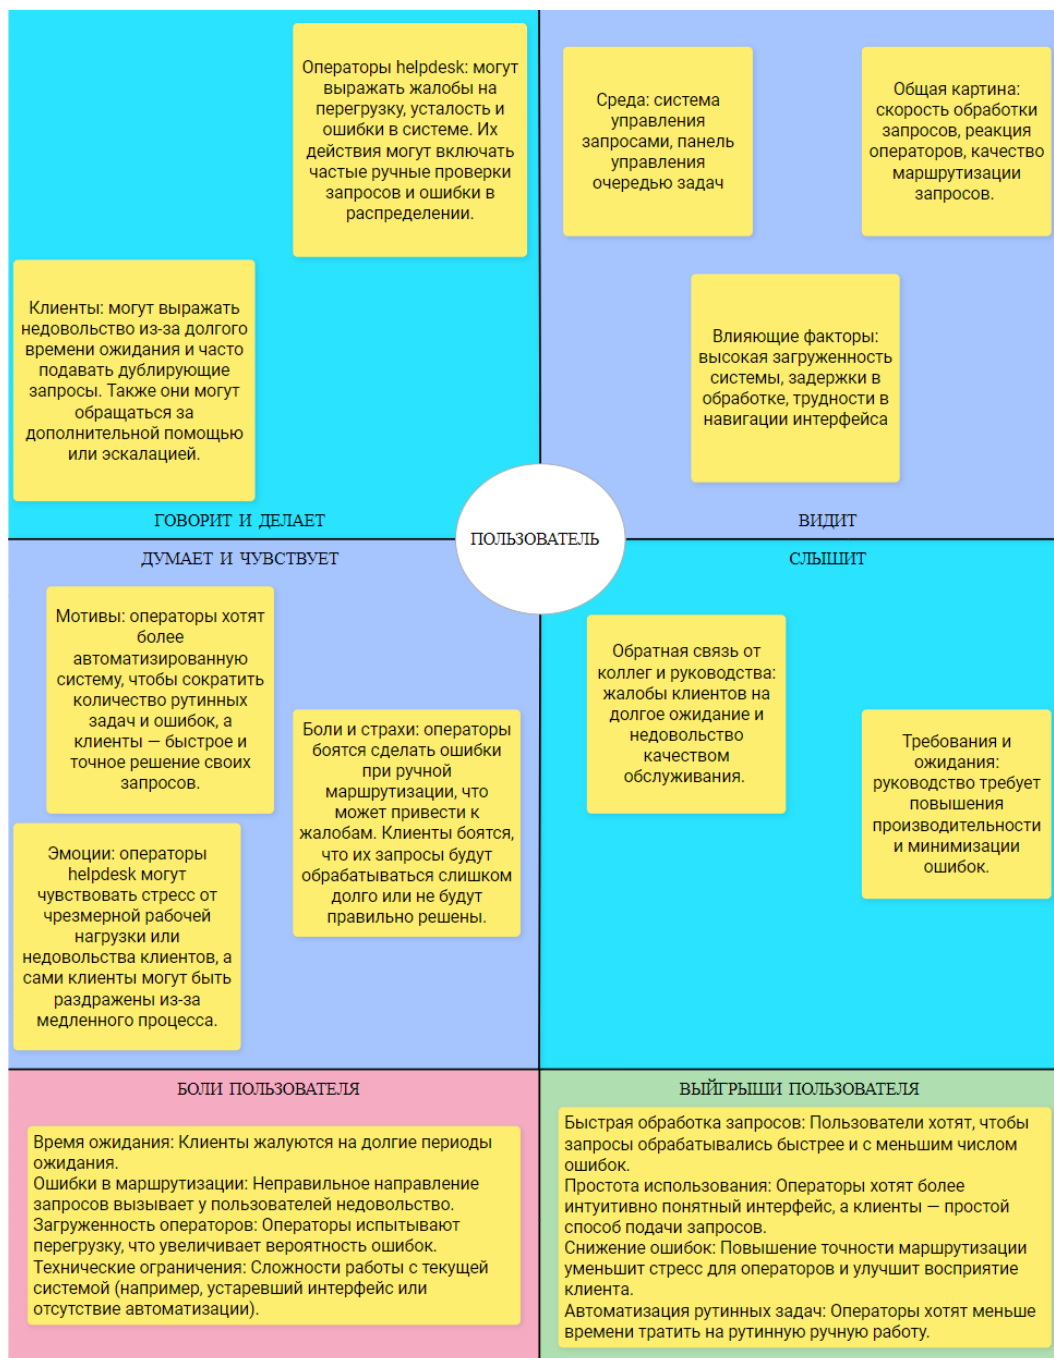


Рисунок 6 - Карта эмпатии

Карта эмпатии помогает сфокусироваться на проблемах, которые важны для пользователей системы, отображена на рисунке, что способствует лучшему пониманию их потребностей и созданию решений, направленных на улучшение взаимодействия и повышения эффективности работы. Каждый элемент карты трансформируется в конкретные требования к функциональности, интерфейсу, производительности или процессам, что улучшает ориентацию системы на реальные задачи и ожидания пользователей.

Рассмотренные модели и методы обеспечивают всестороннее понимание как внутренних, так и внешних факторов, влияющих на успешное создание ценности для клиентов. Это теоретико-методологическое обоснование станет основой для дальнейшего анализа практических аспектов исследования, а также для формирования рекомендаций по оптимизации процессов создания и доставки ценности.

1.4 Сбор и отбор научных материалов

Многочисленные научные работы посвящены исследованию возможностей использования машинного обучения в современной жизни. Для проведения диссертационного исследования был произведен сбор данных и научных материалов с применением технологии библиографической эвристики и методов поиска информации: выборочного, интуитивного, типологического, индуктивного, дедуктивного, метода библиографических ссылок, метода восхождения от абстрактного к конкретному.

Были отобраны и изучались научно-исследовательские публикации:

- монографии с систематическим изложением основных данных научного труда по теме машинного обучения и тесно связанными темами по методам обработки входящих запросов;
- авторефераты диссертаций с кратким изложением научного исследования методов машинного обучения классификации текстовых запросов;

- методические разработки со вспомогательными данными, определяющими план изложения результатов научных исследований в области автоматизации и оптимизации распределения заявок;
- тезисы докладов и материалы научных конференций с краткими формулировками ключевых научных идей по исследованию использования машинного обучения;
- научные статьи с отдельным научным исследованием, отражающие новый теоретический, аналитический или экспериментальный научный результат исследования.

В процессе отбора источников информации применялось несколько критериев к содержанию, а именно:

- критерий актуальности, отражающий реальное состояние объекта исследования в настоящее время;
- критерий достоверности, доказывающий истинность и правдивость полученных результатов;
- критерий объективности, точное воспроизведение истинного положения и развития объекта исследования;
- критерий информационного единства, применение системы показателей, максимально снижающих противоречия в выводах и согласующих первичные и полученные данные;
- критерий релевантности информации, отбираются только данные, напрямую относящиеся к проводимому исследованию.

Далее необходимо проанализировать собранные материалы с точки зрения целей и задач исследования, эффективности, переосмыслить материалы, выработать новые выводы, сформировать предложения практического применения и документирования результатов исследования.

1.5 Применение машинного обучения в задачах классификации и обработки запросов: анализ научных исследований

Исследование опирается на теоретические концепции машинного обучения и применения их в области обработки запросов, включает в себя работы, посвященные алгоритмам машинного обучения, обработке естественного языка и технологиям, направленным на автоматизацию процессов helpdesk. В частности, исследуются алгоритмы классификации, кластеризации, искусственные нейронные сети и их применение для повышения производительности helpdesk-систем.

В ряде научных работ, включая исследования Т.В. Батуры «Методы автоматической классификации текстов» [5], Е.И. Большаковой «Автоматическая обработка текстов на естественном языке и анализ данных» [6], А.В. Комаровой «Метод автоматизированного извлечения адресов из неструктурированных текстов» [14], П.Р. Варшавского «Реализация программных средств для классификации данных на основе аппарата сверточных нейронных сетей и прецедентного подхода» [7], Ю.С. Кашницкого «Ансамблевый метод машинного обучения, основанный на рекомендации классификаторов» [1][31], В.Н. Клячкина «Выбор метода бинарной классификации при технической диагностике с применением машинного обучения» [12], И.А. Кузнецова «Методы и алгоритмы машинного обучения для предобработки и классификации слабоструктурированных текстовых данных в научных рекомендательных системах» [21], К.И. Лунева «Особенности применения машинного обучения для классификации текстовых документов» [22][25] и М.Т. Нгуена «Тестирование методов машинного обучения в задаче классификации HTTP-запросов с применением технологии tf-idf» [27], подробно анализируются методы автоматической обработки и классификации текстов. Эти работы охватывают широкий спектр алгоритмов машинного обучения, включая методы классификации текстовых данных, извлечение структурированной информации из неструктурированных

текстов, подходы к обработке данных с использованием нейронных сетей и ансамблевых методов [33]. Значительное внимание уделяется предобработке текстов, оценке их признаков и выбору подходящих метрик для классификации, а также тестированию эффективности различных моделей в задачах, таких как диагностика, анализ запросов и рекомендации [2][42]. Тем не менее, несмотря на богатый материал по применению этих алгоритмов в задачах классификации текстов, их использование для обработки входящих запросов в helpdesk-подразделениях крупных организаций детально не исследовалось [3]. Это оставляет значительное поле для анализа и адаптации существующих методов в контексте специфики таких систем, включая их зависимость от объема данных, многообразия запросов и требований к скорости обработки. В работе «Методы автоматической классификации текстов» Т.В. Батура анализирует возможные трудности и ошибки, возникающие при формировании обучающей выборки. Автор обобщает достижения других исследователей в области машинного обучения и предлагает теоретические модели, объясняющие особенности создания обучающих данных [32]. Исследование включает разработку методов улучшения процесса формирования выборки и содержит практические рекомендации, основанные на представленных моделях. Завершают труд результаты экспериментов, демонстрирующие ключевые проблемы формирования обучающих данных и способы их решения на примере алгоритмов обучения деревьев решений.

В сфере распознавания состояния технических объектов в ходе их эксплуатации особое внимание уделяется преждевременному выявлению неисправностей и их немедленному устранению в процессе технического обслуживания. Диагностика сводится к разделению на два основных класса: исправное и неисправное, поэтому тут могут применяться методы машинного обучения, спроектированные для бинарной классификации [41].

В исследовании П.Р. Варшавского и А.В. Кожевникова «Реализация программных средств для классификации данных на основе аппарата

сверточных нейронных сетей и прецедентного подхода» проведен анализ известных результатов, представленных в форме прецедентов. Эти прецеденты используются в качестве исходных данных для оценки состояния системы, что позволяет обосновать применимость выбранных методов классификации [13]. В исследовании применены различные подходы к бинарной классификации, включая традиционные статистические модели, методы, специализированные для области машинного обучения, и композиционные методы. Для улучшения точности прогнозирования предложен агрегированный подход, основанный на комбинировании нескольких методов классификации.

Выводы по первому разделу.

В данном разделе проведено исследование принципов функционирования helpdesk-систем, выявлены их ключевые проблемы и возможные подходы к решению. Обзор научных трудов позволил получить актуальное представление о современных подходах к обработке запросов и методах, применяемых для повышения эффективности работы helpdesk. На основании анализа были определены цели, достижение которых планируется в течение одного года, а также разработаны базовые инструменты бизнес-моделирования, включая модель мотивации бизнеса, карту пути клиента и поток создания ценности. Это позволило структурировать и визуализировать процессы создания и передачи ценности, обеспечивая всесторонний анализ стратегии, операционных механизмов и потребностей целевой аудитории.

Таким образом, можно заключить, что бизнес-анализ играет ключевую роль, особенно для ИТ-компаний. В контексте подразделений helpdesk он способствует повышению качества обслуживания клиентов. Выявляя проблемные области, вроде таких как длительное время ожидания или некорректное распределение запросов, организация получает возможность внедрять изменения, оптимизирующие работу этих процессов.

2 Анализ технологий машинного обучения

Для решения задачи автоматизации обработки потока текстовых запросов в helpdesk подразделение целесообразно применить метод классификации запроса и машинное обучение.

Существуют различные методы классификации со своим математическим аппаратом и подходом к реализации. На получаемый от применения метода эффект большое влияние оказывает конкретные условия поставленной задачи [23]. В последние годы проблема повышения качества машинного обучения привлекает значительное внимание исследователей. На сегодняшний день не существует универсального метода, который мог бы эффективно решать задачи классификации во всех возможных условиях [20, с. 174]. В области машинного обучения существует теорема «No Free Lunch», согласно которой ни один алгоритм не является лучшим для всех типов задач. Это подчеркивает важность выбора метода классификации, который должен быть адаптирован под конкретные особенности задачи и ее условия.

2.1 Методы классификации текстовых запросов

Процесс классификации текстовых запросов, поступающих в службу технической поддержки, представляет собой важную задачу, направленную на автоматизированное распределение заявок по категориям. Такая категоризация основывается на содержании запросов и позволяет оптимизировать обработку данных, повысить точность обработки и сократить время отклика [24]. Реализация классификации может осуществляться несколькими способами, включая ручное распределение, применение фиксированных правил и использование методов машинного обучения. Алгоритм отражен на рисунке 7.

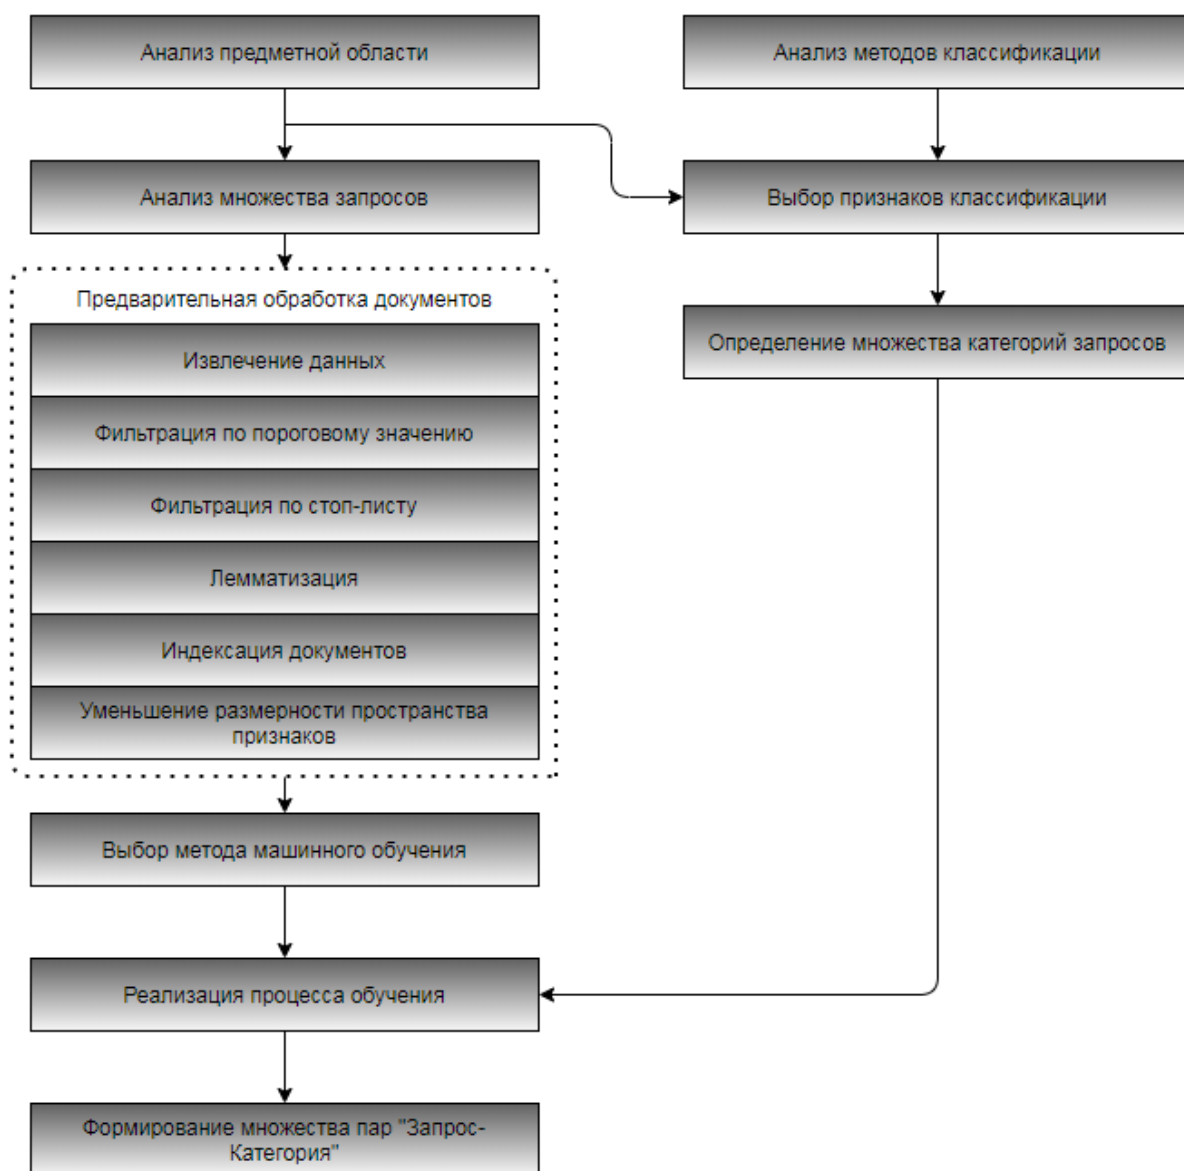


Рисунок 7 – Схема с формализованным алгоритмом процедур классификации входящих запросов

Наиболее современным и перспективным подходом является машинное обучение, позволяющее автоматизировать сложные процессы анализа данных [34]. Обучение классификационных алгоритмов строится на обработке размеченных данных, где каждому запросу заранее присвоена категория. Этот процесс позволяет модели выявлять ключевые признаки, характерные для каждой категории, и применять эти знания для работы с новыми данными. Например, использование таких подходов, как обучение с учителем, делает

процесс классификации более адаптивным к изменяющимся условиям, сохраняя высокую точность результатов.

Классификация текстов включает несколько этапов. Одним из начальных шагов является формализация информационных потоков, предусматривающая создание модели, способной обрабатывать запросы с высокой степенью эффективности. Далее следует этап изучения методов классификации, таких как иерархический и фасетный подходы. Первый позволяет строить древовидные структуры категорий, а второй — учитывать множество характеристик, что делает анализ данных более детализированным.

Определение признаков классификации играет центральную роль в повышении точности. На этом этапе выделяются ключевые элементы запросов, такие как тема, ключевые слова и приоритет. Процесс предварительной обработки данных, включающий извлечение текста, удаление стоп-слов, лемматизацию и индексирование, подготавливает данные для последующего анализа. Методы векторизации, такие как TF-IDF или Word2Vec, обеспечивают преобразование текста в числовой формат, подходящий для работы алгоритмов.

В зависимости от особенностей данных и поставленных задач для классификации используются различные алгоритмы, включая деревья решений, наивный Байес, случайные леса и нейронные сети. Современные подходы, такие как глубокое обучение с использованием трансформеров (например, BERT), позволяют учитывать сложные зависимости в текстах, обеспечивая высокую производительность моделей.

Создание систем классификации, которые предоставляют упорядоченные результаты, например, в формате "запрос-категория", позволяет значительно повысить уровень автоматизации работы служб технической поддержки, увеличивая их эффективность и точность.

2.2 Методы машинного обучения для классификации текстовых запросов

Машинное обучение становится ключевым инструментом в задачах классификации текстовых запросов, поскольку оно предоставляет возможность обработки больших объемов данных с целью выявления скрытых закономерностей. Сфера применения машинного обучения охватывает широкий спектр задач, включая классификацию, регрессию и кластеризацию, в соответствии с рисунком 8.

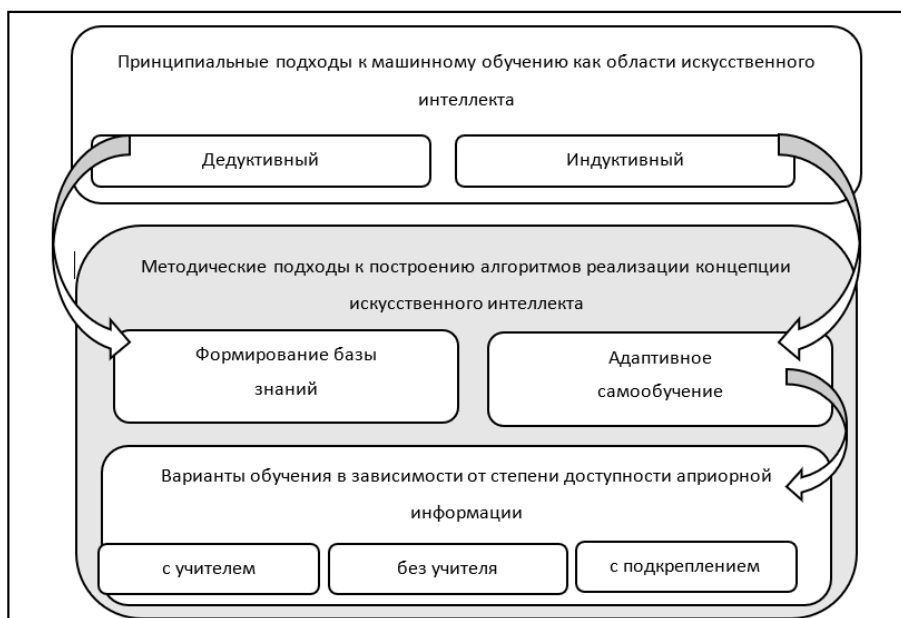


Рисунок 8 – Классификация методов машинного обучения

Основными подходами машинного обучения являются обучение с учителем, обучение без учителя и обучение с подкреплением. В контексте классификации текстов наиболее подходящим считается обучение с учителем, поскольку оно предполагает использование размеченных данных, где запросы уже распределены по категориям. Анализируя такие данные, алгоритм выстраивает модели, которые способны прогнозировать категорию новых запросов на основе их характеристик.

Процесс классификации начинается с выделения признаков, которые являются основой для анализа. Такие признаки, как частота слов, ключевые термины или длина текста, определяют основу анализа текстов. Методы векторизации, включая TF-IDF, Bag of Words, Word2Vec и FastText, позволяют преобразовать текстовую информацию в числовой вид, пригодный для дальнейшего машинного анализа [38].

На следующем этапе производится выбор и настройка алгоритмов обучения. Среди широко используемых методов — деревья решений, наивный Байес, случайные леса и нейронные сети. Глубокое обучение предоставляет более сложные инструменты анализа, такие как свёрточные сети (CNN), рекуррентные сети (RNN) и трансформеры. Эти технологии особенно эффективны при работе с большими и сложными наборами данных, поскольку они позволяют учитывать как семантические, так и синтаксические связи в текстах [18].

Для проверки производительности модели применяется тестирование на независимых наборах данных [17]. Эффективность работы оценивается с использованием метрик, таких как точность, полнота и F1-score, что обеспечивает объективный подход к анализу качества модели. При необходимости проводится оптимизация параметров модели, что позволяет повысить её надежность и адаптивность.

Системы, созданные на основе машинного обучения, представляют собой мощные инструменты для классификации запросов. Они способствуют не только автоматизации процессов, но и улучшению качества работы служб поддержки, что значительно повышает общую удовлетворённость клиентов.

2.3 Обзор существующих решений

Обзор существующих решений для автоматизации обработки входящих запросов в helpdesk демонстрирует разнообразие подходов и технологий, используемых на рынке.

Zendesk Support Suite выделяется своей мощной функциональностью и активным применением машинного обучения. Алгоритмы платформы способны не только автоматически классифицировать запросы, но и адаптироваться к изменениям на основе исторических данных. Кроме того, Zendesk предоставляет обширные возможности интеграции с популярными инструментами, такими как Slack и Salesforce, что делает его удобным для организаций, уже использующих эти решения. Однако использование Zendesk в России сталкивается с рядом вызовов, включая ограничение доступа к облачным сервисам из-за санкций, а высокая стоимость лицензий усложняет его внедрение для компаний среднего масштаба [8].

Freshdesk, в свою очередь, делает акцент на удобстве использования и мультиканальном взаимодействии. Платформа поддерживает мессенджеры, электронную почту и социальные сети, предоставляя универсальное решение для поддержки клиентов. Freddy AI, встроенный в Freshdesk, помогает обрабатывать запросы, автоматически предлагая готовые ответы и классифицируя входящие обращения. Но хранение данных на зарубежных серверах представляет потенциальную угрозу для конфиденциальности, особенно для компаний, работающих в странах с жесткими требованиями к локализации данных.

ServiceNow ITSM является одним из наиболее мощных инструментов для крупных предприятий, специализирующихся на сложных IT-операциях. Машинное обучение в ServiceNow нацелено на управление жизненным циклом запросов, включая их автоматическое распределение по приоритетам. Однако сложная настройка и необходимость привлечения высококвалифицированных специалистов для управления системой увеличивают расходы на внедрение и сопровождение. Кроме того, платформа также сталкивается с ограничениями в России по аналогии с Zendesk и Freshdesk.

На российском рынке Naumen Service Desk позиционируется как локальная альтернатива с фокусом на соответствие требованиям

законодательства. Благодаря хранению данных внутри страны и поддержке русского языка платформа популярна среди организаций, которым важно соблюдение нормативных актов, например, Федерального закона № 152-ФЗ о персональных данных. Однако Naumen имеет ограниченную гибкость в плане настройки и меньше функциональных возможностей по сравнению с зарубежными аналогами.

1С:ИТС и ITSM 365 представляют собой более доступные решения для автоматизации helpdesk. В случае 1С основной акцент делается на глубокую интеграцию с другими продуктами экосистемы 1С, что полезно для компаний, уже использующих бухгалтерское и управленческое ПО этой платформы [28]. Однако отсутствие современных алгоритмов машинного обучения ограничивает его эффективность в обработке сложных запросов. ITSM 365, облачная платформа, напротив, поддерживает базовые алгоритмы классификации, что позволяет обрабатывать входящие запросы быстрее и с меньшими затратами. Тем не менее, простота реализованных методов ограничивает её конкурентоспособность на рынке, особенно в задачах обработки естественного языка, где требуется высокий уровень точности.

Для сравнения систем обработки входящих запросов добавим их ключевые параметры в таблицу 2, а также рассмотрим стоимость для команды из 30 сотрудников.

Таблица 2 – Сравнение систем обработки входящих запросов

Программа	Преимущества	Недостатки	Стоимость для 30 сотрудников	Легкость внедрения	Интерфейс и опыт пользователя	Метрики и отчеты	Требования к ресурсам
Zendesk Support Suite	интеграция с множеством платформ, мощные аналитические инструменты	высокая стоимость, сложность настройки	от \$1650/мес.	средняя (интерфейс и автоматизация)	удобный, но можно улучшить кастомизацию	подробные отчеты по SLA, времени разрешения	средние требования, облачное решение
Freshdesk	удобный интерфейс, бесплатный базовый план	высокая стоимость, необходимость хранения данных за границей	от \$450 до \$2370/мес.	легкое внедрение, простота	понятный интерфейс, кастомизация ограничена	стандартные отчеты	низкие требования, облачный сервис
ServiceNow ITSM	высокая масштабируемость, глубокая аналитика	сложная настройка, высокая стоимость, санкционные ограничения	от \$3600/мес.	трудоемкое внедрение	интуитивно понятный для больших команд	подробные отчеты по SLA, тренды	средние требования
Naumen Service Desk	локализация для РФ, адаптивность	уступает по гибкости и функциональности зарубежным решениям	от 500000 руб./год	средняя	простота и доступность для пользователей	стандартные отчеты	средние требования
1С:ИТС	интеграция с 1С, низкая стоимость	ограниченные возможности машинного обучения	от 60000 руб./год	легкое внедрение в экосистему 1С	устаревший интерфейс, ограниченная кастомизация	стандартные отчеты	низкие требования
ITSM 365	гибкость настройки, поддержка базовых алгоритмов машинного обучения	ограниченная поддержка технологий обработки текста	от 300000 руб./год	средняя (зависит от модуля)	удобный интерфейс, но сложная настройка	стандартные отчеты	средние требования

В таблице 3 сравним преимущества и недостатки методов, используемых в вышеуказанных решениях.

Таблица 3 – Сравнение методов машинного обучения в существующих решениях

Программа	Методы машинного обучения	Преимущества методов	Недостатки методов
Zendesk Support Suite	нейросети, кластеризация запросов	высокая точность анализа; адаптивность к новым данным; поддержка многоклассовой классификации	высокие вычислительные затраты; требует больших объемов обучающих данных
Freshdesk	нейросети, автоматизация тегирования	автоматическое тегирование улучшает сортировку; простота реализации для типичных сценариев	ограниченные возможности в обработке сложных запросов; может быть неточно при малообъемных данных
ServiceNow ITSM	нейросети, обработка на естественном языке	глубокое понимание контекста текст; возможность построения сложных маршрутизаций	высокие требования к вычислительным ресурсам; может дать сбой при неоднозначных запросах
Naumen Service Desk	логистическая регрессия, деревья решений	простота и скорость реализации; легкая интерпретация результатов	ограниченная эффективность на сложных данных; может быть подвержен переобучению
1С:ИТС	простые классификаторы, правила	минимальные затраты на внедрение; прозрачные и понятные алгоритмы	ограниченная гибкость; плохая масштабируемость на больших данных
ITSM 365	логистическая регрессия, SVM	хорошо справляется с задачами классификации; высокая скорость обучения на средних объемах данных	SVM плохо работает с большими объемами данных; логистическая регрессия ограничена в обработке нелинейных данных

Для обработки входящих текстовых запросов в helpdesk, кроме методов, уже упомянутых в анализе, можно использовать несколько дополнительных

подходов машинного обучения. Методы на основе графов, такие как графовые нейронные сети (GNN), могут анализировать взаимосвязи между запросами, категориями или клиентами, выявляя скрытые зависимости [39]. Это особенно полезно для рекомендаций на основе исторических данных. Однако такие методы сложны в реализации и требуют значительных вычислительных ресурсов.

Генеративные модели, например, GPT или BART, обеспечивают высокую точность в задачах генерации текста, включая автоматическое составление ответов [9]. Они идеально подходят для создания чат-ботов, способных отвечать на запросы клиентов. Тем не менее, они требуют больших вычислительных мощностей и иногда могут генерировать неправильные или нерелевантные ответы.

Системы автоматического машинного обучения (AutoML) используют ансамбли алгоритмов с автостэкингом для минимизации ручной настройки и повышения универсальности решений. Такие подходы находят оптимальные комбинации моделей для задач классификации, но могут потребовать больше времени для обучения и сложнее в интерпретации результата.

Методы метаобучения (meta-learning) позволяют быстро адаптировать модели к новым данным с минимальными затратами. Это особенно актуально в условиях изменяющихся сценариев работы helpdesk, где важно оперативно адаптироваться к новым типам запросов. Однако данные методы сложны в реализации и требуют тщательно подобранных данных.

Семантическое сопоставление с использованием трансформеров, таких как BERT, позволяет учитывать контекст текстовых запросов, что особенно полезно для точной классификации или маршрутизации запросов. Эти модели обеспечивают высокую производительность, но требуют значительных ресурсов памяти и вычислений.

Анализ существующих решений показывает, что большинство современных платформ для обработки входящих запросов в helpdesk-подразделениях предлагает функционал автоматической классификации и

маршрутизации запросов. Однако имеются существенные ограничения, которые делают целесообразным разработку нового программного обеспечения:

- высокая стоимость зарубежных решений. Такие платформы, как Zendesk, Freshdesk и ServiceNow, предлагают широкий спектр функций, но их высокая стоимость делает их недоступными для большинства российских компаний, особенно малого и среднего бизнеса [29].
- санкционные ограничения. Из-за текущих геополитических условий использование зарубежных продуктов может быть затруднено или даже невозможно. Кроме того, хранение данных на зарубежных серверах противоречит требованиям российского законодательства (ФЗ-152).
- ограниченные возможности российских решений. Хотя российские платформы соответствуют законодательным требованиям, их функциональность в части машинного обучения уступает зарубежным аналогам. Многие из них используют устаревшие или менее точные алгоритмы, что сказывается на эффективности обработки запросов.
- отсутствие специализированного решения для определённых задач. Большинство существующих платформ ориентированы на широкий круг пользователей и не учитывают особенности конкретных бизнес-процессов [19]. Новое решение может быть адаптировано под специфические требования отдельных отраслей, что увеличит его ценность для пользователей.

Таким образом, разработка нового программного обеспечения, основанного на современных методах машинного обучения, будет способствовать созданию конкурентоспособного продукта, способного удовлетворить потребности российского рынка. Новый инструмент должен

быть локализованным, гибким и экономически доступным, что делает его привлекательным как для крупных, так и для средних и малых предприятий.

Эффективное построение ансамбля алгоритмов классификации требует исследования способов и особенностей его реализации применительно к задаче классификации текстовых запросов.

2.4 Моделирование бизнес-процесса «Как есть»

Проведём анализ бизнес-процесса с использованием стандарта IDEF0. Этот стандарт предназначен для разработки функциональных моделей, которые показывают структуру и функции системы, а также информационные и материальные потоки, связывающие эти функции. Применяя IDEF0 и анализируя деятельность подразделения технической поддержки (helpdesk), мы сможем создать контекстную диаграмму текущего состояния, «Как есть», и ее декомпозицию, в соответствии с рисунками 9 и 10.

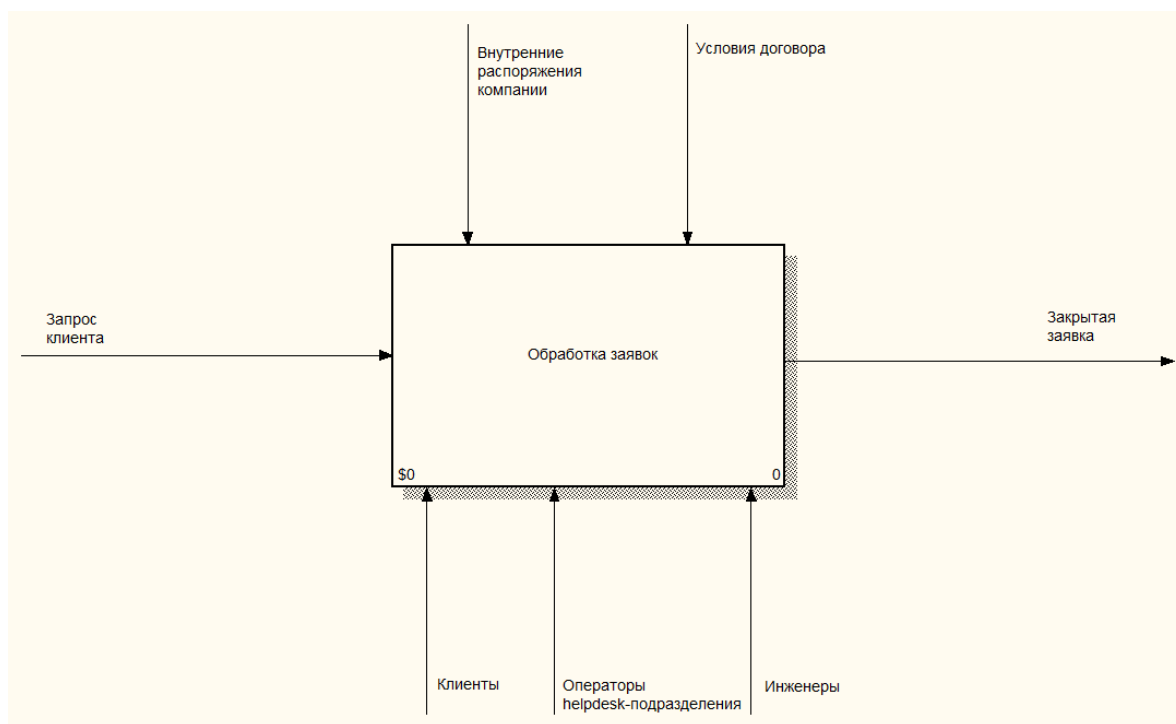


Рисунок 9 – Диаграмма «Как есть»

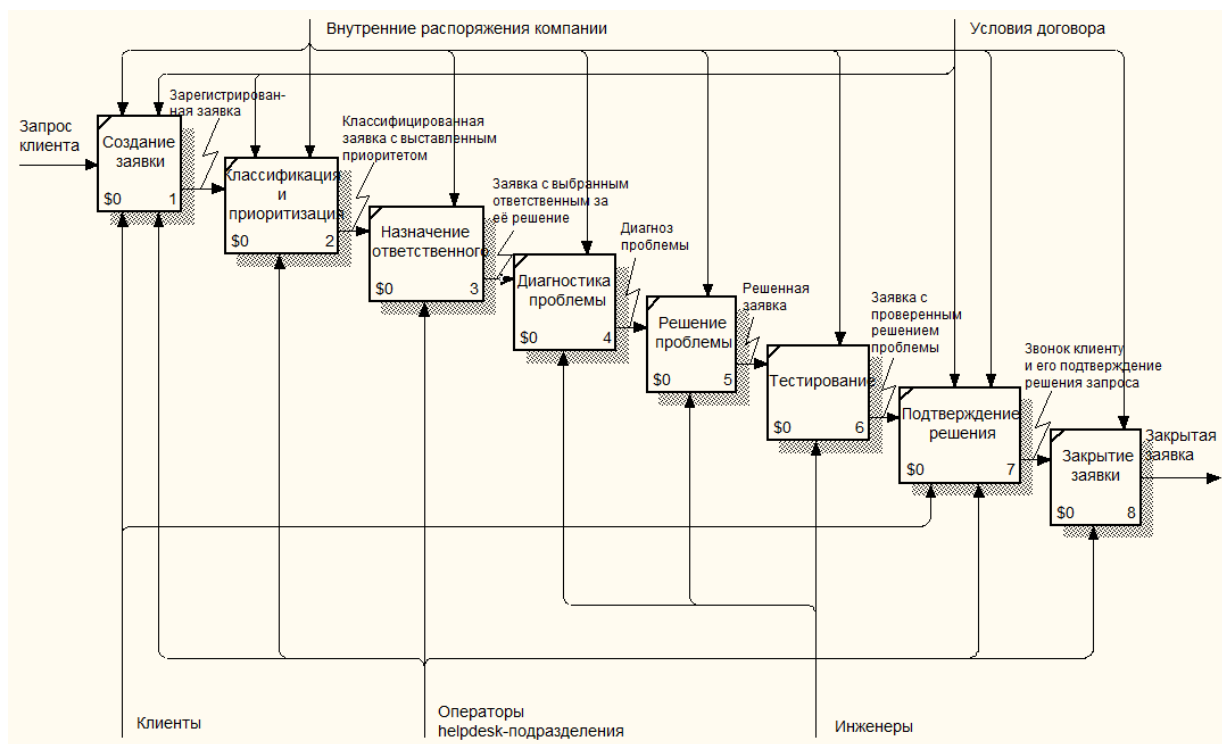


Рисунок 10 – Декомпозиция диаграммы «Как есть»

Эти диаграммы позволят лучше понять существующий процесс и выявить области для возможных улучшений.

В типичном бизнес-процессе обработки заявок helpdesk подразделением производится последовательность следующих действий:

- клиент отправляет запрос через телефон, email или веб-портал. Заявка регистрируется в системе управления заявками;
- оператор helpdesk подразделения классифицирует запрос по типу проблемы (программная ошибка, сбой оборудования и т.д.), определяет приоритет заявки (низкий, средний, высокий);
- оператор helpdesk подразделения назначает заявку конкретному специалисту или команде;
- исполнитель анализирует заявку, изучает детали проблемы, проводит диагностику для выявления причин неисправности;

- исполнитель разрабатывает и реализует решения проблемы. При необходимости - привлекает дополнительные ресурсы или передает другой команде;
- тестирование решения. Подтверждение устранения проблемы;
- закрытие заявки после решения проблемы и получения оператором helpdesk подразделения подтверждения от клиента.

Важным шагом для визуализации и анализа потоков информации бизнес-процесса обработки запросов в helpdesk является создание диаграммы потоков данных, в соответствии с рисунком 11. Это помогает своевременно выявить и устранить узкие места, повысить эффективность и точность, улучшить коммуникацию и сотрудничество, обеспечить безопасность данных и соответствие требованиям, поддерживать разработку и внедрение систем, а также улучшить клиентский опыт.

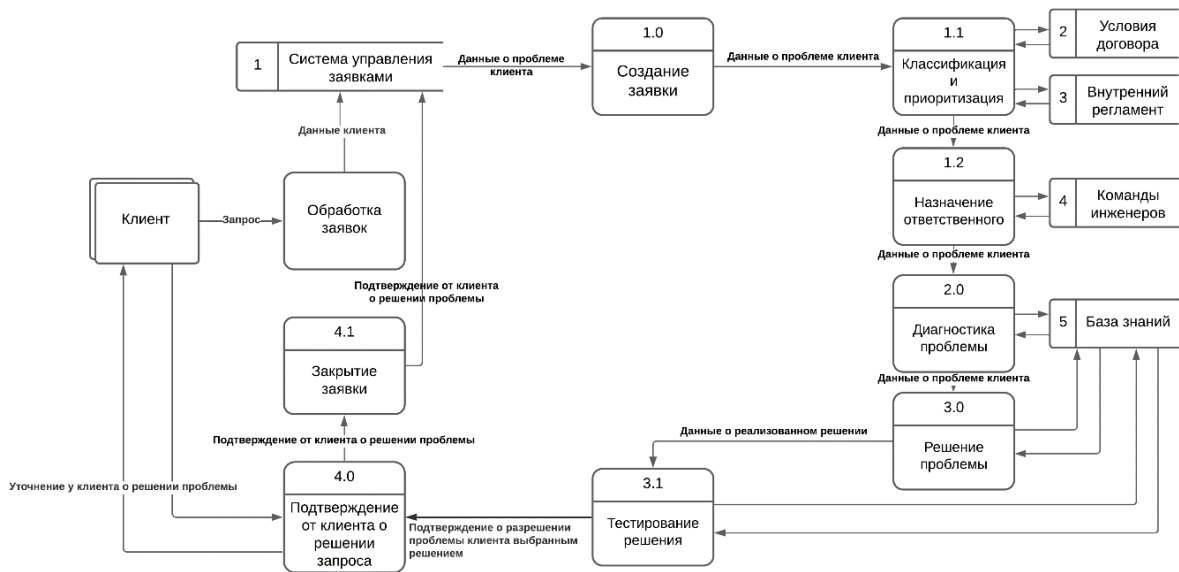


Рисунок 11 – Диаграмма потоков данных

Структурировать и описывать обязанности различных участников и подпроцессов в рамках одного бизнес-процесса помогает применение такого

инструмента, как построение кросс-функциональной карты, в соответствии с рисунком 12.

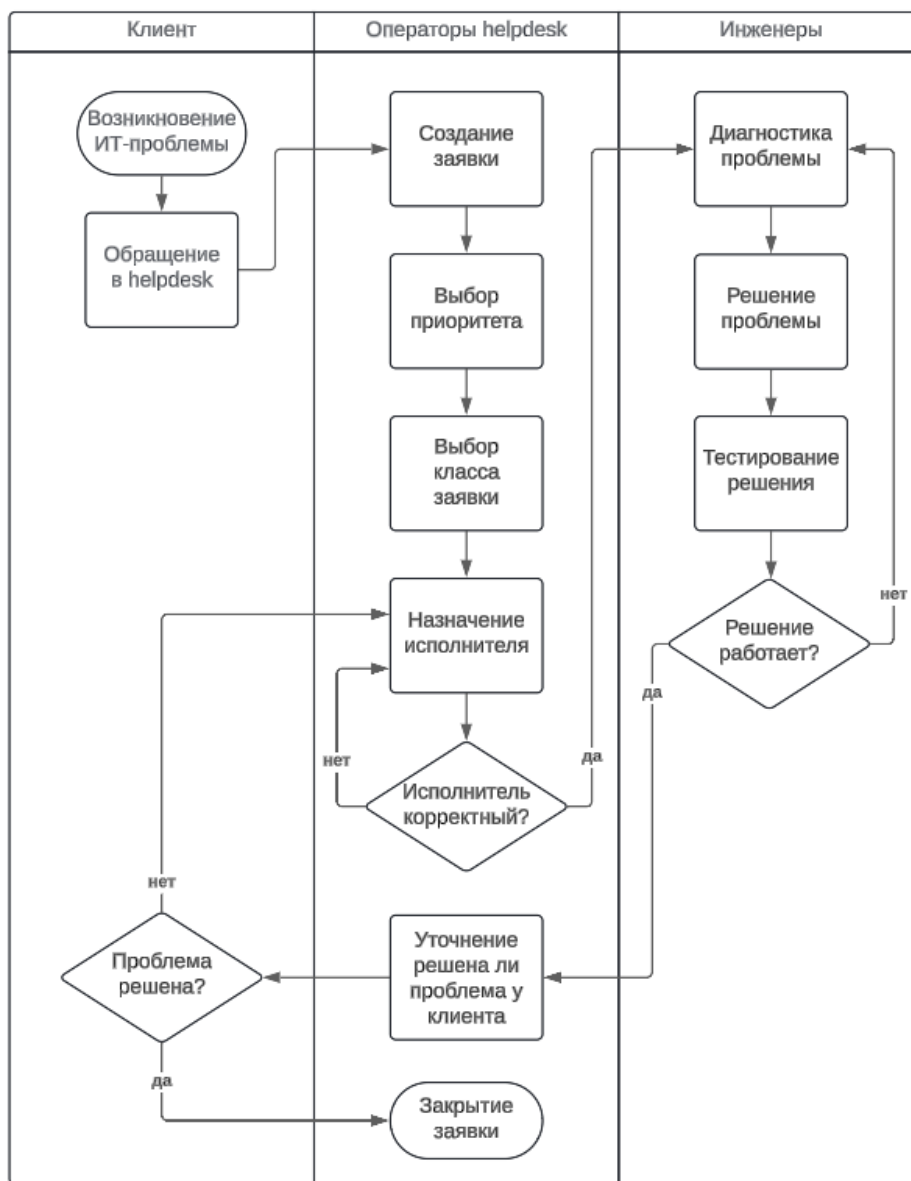


Рисунок 12 – Кросс-функциональная карта

Он четко отображает все этапы процесса обработки заявок и показывает, кто за что отвечает. Это помогает всем участникам процесса (операторам техподдержки, инженерам, менеджерам и т.д.) ясно понимать свои роли и обязанности, что снижает потенциальную вероятность ошибок.

2.5 Анализ методов обработки входящих запросов

Распределение заявок в рабочей среде может происходить различными способами, в том числе циклическим, синхронным и автоматизированным.

Рассмотрим каждый из этих вариантов.

Циклическое распределение: задачи распределяются между участниками или членами команды по очереди в определенном порядке. Каждый участник получает задачу, затем следующий, и так далее, циклически.

Плюсы:

- простота реализации (этот метод прост в настройке и управлении, что делает его доступным для небольших команд или организаций);
- равномерное распределение по количеству задач (каждый участник в цикле получает задачу поочередно).

Минус:

- неравномерное по сложности распределение (некоторые участники могут столкнуться с более сложными задачами, чем другие, что может привести к неравномерной загрузке).

Синхронное распределение: задачи распределяются с учетом текущей загрузки участников и их навыков. Система стремится к равномерной загрузке участников, учитывая их способности и текущую активность.

Плюс:

- задачи распределяются между участниками с учетом их текущей загрузки и навыков, что способствует более равномерной загрузке. Позволяет балансировать рабочую нагрузку и избегать перегрузок.

Минусы:

- сложность управления (реализация синхронного распределения может потребовать более сложных систем управления и мониторинга);
- временные затраты (не всегда подходит для ситуаций, где необходимо быстро реагировать на поступившие запросы).

Автоматизированное распределение: задачи распределяются автоматически с использованием специализированных программных решений или систем управления задачами. Автоматизированные системы могут учитывать различные параметры при распределении, такие как приоритет задачи, сроки, навыки участников и другие факторы.

Плюсы:

- эффективность (автоматизированные системы способны быстро и эффективно распределять задачи в соответствии с заранее определенными правилами);
- адаптивность (могут быстро адаптироваться к изменяющимся условиям и требованиям).

Минусы:

- сложность настройки (внедрение автоматизированной системы может потребовать значительных усилий и времени для ее настройки и оптимизации);
- потребность в обучении (пользователи и администраторы должны быть обучены в работе с автоматизированными системами).

Каждый из этих подходов имеет свои сильные и слабые стороны, и выбор конкретного метода зависит от особенностей задач, характеристик команды и бизнес-процессов организации.

В разрезе рассматриваемой задачи плюсы автоматизированного метода значительно важнее минусов. Автоматическое равномерное распределение запросов минимизирует время простоя.

2.6 Моделирование бизнес-процесса «Как должно быть»

Построим диаграмму IDEF0 «Как должно быть» с учетом внедрения системы с использованием машинного обучения и отразим ее детальнее в декомпозиции на рисунках 13 и 14.

Система машинного обучения будет определять входит ли решение указанной проблемы в условия договора с конкретным клиентом, проверять наличие и информацию во вложениях, предлагать классификацию, приоритезацию заявок, выбирать подходящего исполнителя.

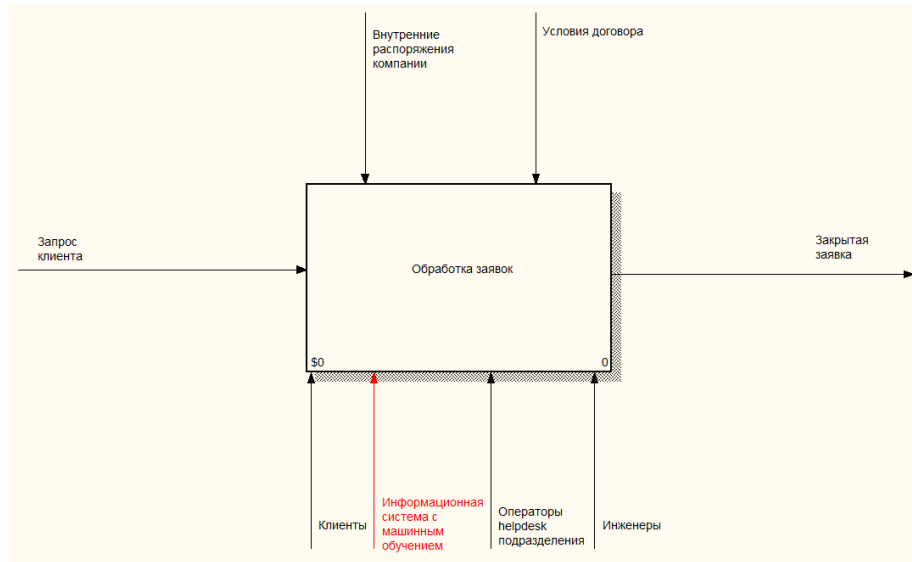


Рисунок 13 – Диаграмма «Как должно быть»

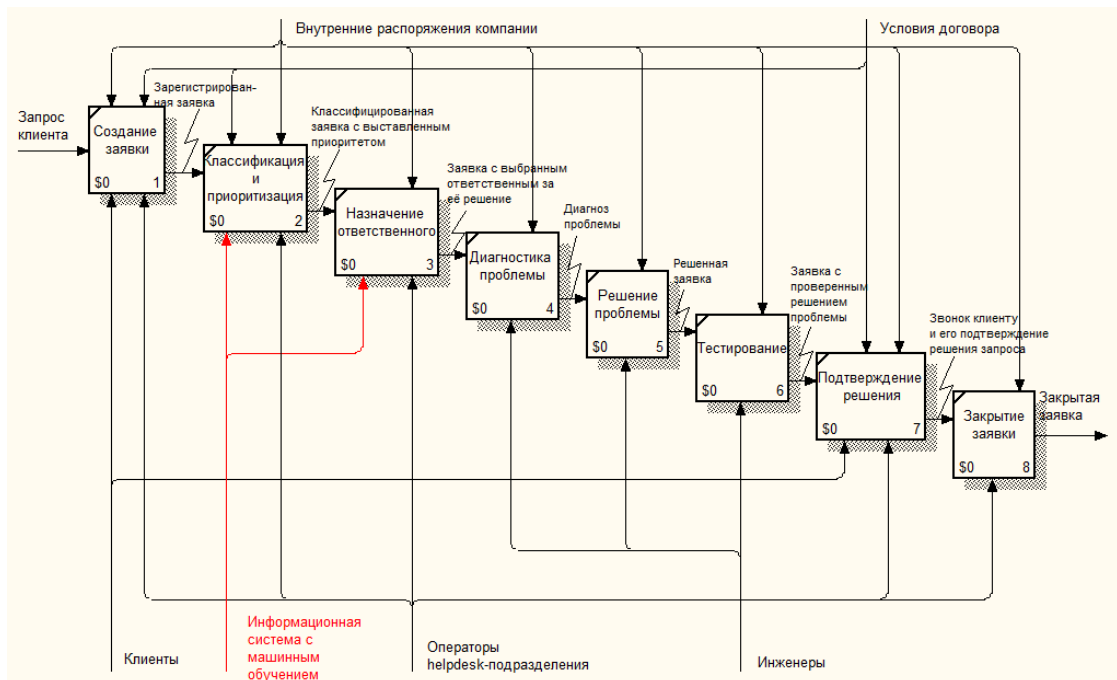


Рисунок 14 – Декомпозиция диаграммы «Как должно быть»

Посредством роли назначаются полномочия пользователей, однозначно разрешающие пользователю производить набор определенных действий в системе. Можно установить режим, позволяющий автоматически назначить исполнителей. Для этого каждому исполнителю ставятся в соответствие категории заявок, и когда создается заявка с определенной категорией, то для ее обработки будет произведено автоматическое назначение соответствующего этой категории исполнителя.

2.7 Альтернативные решения для автоматизации

Основная задача области исследования - автоматизация процессов классификации, распределения и обработки запросов с использованием методов машинного обучения (ML). Цель внедрения технологий машинного обучения - улучшение показателей, таких как среднее время обработки запросов, удовлетворенность клиентов и процент автоматизированных решений.

Рассмотрим возможные альтернативные решения для автоматизации и улучшения показателей такие, как «Использование системы на основе бизнес-правил (Business Rules Engine, BRE)» и «Модернизация системы управления запросами с помощью улучшенных рабочих процессов и интеграций».

Правила-ориентированная система использует заранее установленные бизнес-правила для автоматизации процессов классификации и распределения запросов. Такие системы могут быть настроены так, чтобы автоматизировать рутинные задачи, задавая определенные действия при возникновении определенных условий. Например, запросы, помеченные как «высокий приоритет», автоматически направляются к определенной группе специалистов, а стандартные запросы, такие как восстановление пароля, сразу решаются с помощью шаблонов.

К преимуществам данного решения можно отнести следующее:

- простота настройки. Система на основе правил легко адаптируется под конкретные процессы компании. Правила могут быть настроены без необходимости глубоких технических знаний;
- прозрачность и контроль. Все правила явно заданы, что делает систему предсказуемой и легко управляемой. Операторы и администраторы могут точно знать, как система принимает решения;
- быстрое внедрение. По сравнению с более сложными системами, BRE можно развернуть и настроить быстрее и с меньшими затратами.

Однако, есть и недостатки:

- ограниченная гибкость. Система плохо справляется с изменяющимися условиями или неструктурированными запросами. Для её обновления требуется ручная настройка правил;
- неэффективность при увеличении сложности. С ростом объема запросов и их разнообразия правила могут стать слишком громоздкими и сложными для управления;
- отсутствие адаптивности. В отличие от систем, использующих машинное обучение, такие системы не учатся на данных и не могут улучшать свои решения со временем.

Модернизация системы управления запросами с помощью улучшенных рабочих процессов и интеграций предполагает внедрение улучшенных рабочих процессов и интеграцию с существующими системами управления для повышения эффективности helpdesk. Улучшенные процессы могут включать в себя автоматизированные триггеры для направления запросов, упрощенные интерфейсы для операторов и клиентоориентированные решения, такие как самослужебные порталы для пользователей, где они могут самостоятельно решать стандартные запросы.

У этого решения также есть как плюсы:

- повышение эффективности за счет интеграции. Интеграция helpdesk-системы с другими ИТ-системами (например, системами управления инцидентами или мониторинга) позволяет ускорить обмен данными

и автоматизировать определенные процессы (например, создание инцидентов или уведомлений);

- самослужебные решения для пользователей. Позволяет клиентам самостоятельно решать стандартные проблемы с помощью базы знаний или шаблонов решений, что снижает нагрузку на операторов;
- улучшенные рабочие процессы. Внедрение четких рабочих процессов и распределение обязанностей операторов улучшает обработку запросов и ускоряет их решение.

Так и минусы:

- зависимость от точной настройки рабочих процессов: чтобы решение работало эффективно, необходимо тщательно проработать рабочие процессы и правила их исполнения, что требует глубокого анализа и мониторинга;
- ограниченная автоматизация: хотя процессы могут быть оптимизированы, это не решает проблему сложных, неструктурированных запросов, которые все еще требуют ручной обработки;
- необходимость регулярных обновлений: Система требует постоянного обновления для соответствия изменениям в бизнес-процессах, что может потребовать дополнительного времени и ресурсов.

Сравним рассматриваемые решения в таблице 4.

Таблица 4 – Сравнение машинного обучения и альтернативных решений

Параметр	Система на основе бизнес-правил	Модернизация системы управления запросами	Решение с использованием машинного обучения
Автоматизация рутинных задач	высокая, если запросы поддаются строгим правилам	средняя, можно автоматизировать только стандартные процессы	очень высокая, автоматизирует как стандартные, так и сложные запросы

Продолжение таблицы 4

Параметр	Система на основе бизнес-правил	Модернизация системы управления запросами	Решение с использованием машинного обучения
Гибкость	низкая: требует ручного обновления правил	средняя: процессы можно улучшить и модернизировать	очень высокая: система обучается на данных и адаптируется к новым ситуациям
Время внедрения	быстрое внедрение	средняя: требует анализа рабочих процессов	долгое: требуется подготовка данных, обучение моделей
Точность распределения запросов	высокая для предсказуемых запросов, низкая для нестандартных	средняя: зависит от настройки рабочих процессов	высокая: алгоритмы обучаются на большом объеме данных и могут точно распределять запросы
Адаптивность	отсутствует, требуется ручное обновление	зависит от уровня интеграций и самослужебных решений	очень высокая: система продолжает учиться и улучшать свои предсказания

Приходим к выводу - интеграция решения с использованием машинного обучения займет продолжительное время, но по всем остальным параметрам оно превосходит прочие рассматриваемые решения.

2.8 Основные бизнес-цели и объем проекта

Определим основные бизнес-цели и объем проекта в соответствии с рисунком 15, это позволит сфокусироваться на наиболее приоритетных задачах, грамотно распределяя ресурсы. Четко сформулированные цели и объем проекта помогают выровнять ожидания всех участников — от руководства до сотрудников, обеспечить прозрачность на всех уровнях и минимизировать риски недопонимания. Определение объема проекта помогает лучше понять границы, в которых он будет реализован, что позволяет планировать бюджет и сроки. Это помогает избежать перерасхода средств и ресурсов. Также, знание объема проекта помогает заранее выявить

возможные риски и подготовить стратегии для их минимизации, что снижает вероятность возникновения проблем на более поздних стадиях внедрения.



Рисунок 15 – Дерево целей проекта.

Проект потребует около 8-9 месяцев на реализацию всех этапов. Ресурсы, которые будут задействованы: человеческие ресурсы (аналитики, разработчики), ИТ-инфраструктура, обучение персонала. Детально план представлен ниже, в таблице 5.

Таблица 5 – План проекта

Этапы	Мероприятия	Ответственные	Сроки (мес.)
Анализ текущего состояния и сбор данных	сбор данных по текущему процессу обработки ИТ-заявок; анализ времени обработки и качества решений; выявление узких мест и проблемных зон	руководитель ИТ-отдела, аналитик данных.	1

Продолжение таблицы 5

Этапы	Мероприятия	Ответственные	Сроки (мес.)
Определение требований и постановка задачи для машинного обучения	определение бизнес-требований к системе машинного обучения; формулирование технических требований к модели	руководитель ИТ-отдела, Data Scientist, аналитик данных.	0,5
Сбор и подготовка данных для обучения модели	сбор исторических данных по ИТ-заявкам; очистка и аугментация данных; разметка данных (при необходимости)	Data Engineer, Data Scientist.	1
Разработка и обучение модели машинного обучения	выбор алгоритмов машинного обучения; разработка и тестирование модели; оценка точности и производительности модели	Data Scientist.	2
Внедрение модели в рабочие процессы	интеграция модели в систему обработки ИТ-заявок; разработка интерфейсов для взаимодействия с моделью; обучение сотрудников работе с новой системой	разработчики ПО, Data Scientist, руководитель ИТ-отдела.	2
Тестирование и настраивание системы	проведение пилотного тестирования; сбор обратной связи от пользователей	Data Scientist, тестировщик, руководитель ИТ-отдела.	1
Полное развертывание и мониторинг	полное внедрение системы в эксплуатацию; непрерывный мониторинг работы системы; регулярное добавление обновленных данных для обработки	руководитель ИТ-отдела, Data Scientist, DevOps-инженер.	1 на развертывание, затем - мониторинг

При внедрении машинного обучения в процесс обработки заявок службы технической поддержки можно ожидать значительных улучшений в течение года. Перечислим ключевые показатели, по которым можно прогнозировать изменения:

- сокращение времени обработки заявок: ожидается, что время, затрачиваемое подразделением helpdesk на обработку заявок, уменьшится вдвое. Это станет возможным благодаря автоматизации рутинных задач и более эффективному распределению ресурсов;
- увеличение точности классификации и приоритезации: Точность классификации заявок, приоритезации их важности, а также корректности назначения исполнителей должна повыситься на 60%. Алгоритмы машинного обучения способны более точно анализировать и распределять заявки, что приведет к более рациональному использованию человеческих ресурсов;
- снижение нагрузки на сотрудников: Нагрузка на сотрудников службы технической поддержки уменьшится на 50%. Это произойдет благодаря тому, что часть задач будет автоматизирована, а сотрудники смогут сосредоточиться на более сложных и творческих задачах, требующих человеческого вмешательства;
- повышение уровня удовлетворенности клиентов: Уровень удовлетворенности клиентов, обратившихся в службу технической поддержки, должен увеличиться на 30%.

Выводы по второму разделу.

В данном разделе рассмотрены существующие российские и зарубежные решения, выявлены их особенности, а также обоснована необходимость разработки нового программного обеспечения.

Особенностью исследования является использование метода машинного обучения множественной классификации для эффективной обработки и распределения запросов клиентов в helpdesk-подразделении крупной компании. Оптимальное качество прогнозирования достигается через использование агрегированного подхода, который включает в себя комбинацию нескольких методов классификации. Такой метод позволяет учесть разнообразные аспекты и специфику запросов.

3 Практическое исследование эффективности использования машинного обучения для обработки входящих запросов

В качестве программного решения использовалось веб-приложение на .NET Core с библиотеками Microsoft.ML для реализации алгоритмов машинного обучения и Atlassian.Net SDK для взаимодействия с Jira через REST API. Использование .NET Core и Microsoft.ML обусловлено их высокой производительностью и удобством разработки. .NET Core позволяет создавать кроссплатформенные приложения, что обеспечивает гибкость при развертывании на различных операционных системах. Microsoft.ML, в свою очередь, предоставляет интуитивно понятный API для реализации машинного обучения, который хорошо интегрируется с экосистемой .NET, минимизируя необходимость использования внешних решений и упрощая разработку. Интеграция с Jira через REST API предоставляет мощные возможности для автоматизации обработки заявок. Atlassian.Net SDK значительно упрощает взаимодействие с Jira, предлагая готовые методы для создания, обновления и маршрутизации заявок. Алгоритм предлагаемого решения отображен на рисунке 16.

В качестве алгоритма машинного обучения был выбран Averaged Perceptron (бинарная классификация), который дополняется методом One Versus All для обеспечения многоклассовой классификации. Автоматический ассистент обеспечивает анализ текста запросов клиентов, производится классификация их средствами машинного обучения, выбирается наиболее доступный и компетентный инженер - специалист службы технической поддержки для последующей работы по запросу. Алгоритм Averaged Perceptron обладает высокой скоростью обучения и низкими вычислительными затратами, что делает его подходящим для задач обработки входящих запросов, где время ответа имеет критическое значение. Это линейный классификатор, который хорошо справляется с текстовыми данными после их векторизации (например, через TF-IDF). Использование

метода One Versus All для многоклассовой классификации позволяет каждому запросу назначить одну из нескольких категорий, сохраняя при этом возможность точного предсказания для каждого класса, даже если классы несбалансированы.

Этот подход также компактен в реализации: в отличие от сложных нейронных сетей, Averaged Perceptron требует меньше памяти и вычислительных ресурсов, что снижает операционные издержки и упрощает масштабирование.

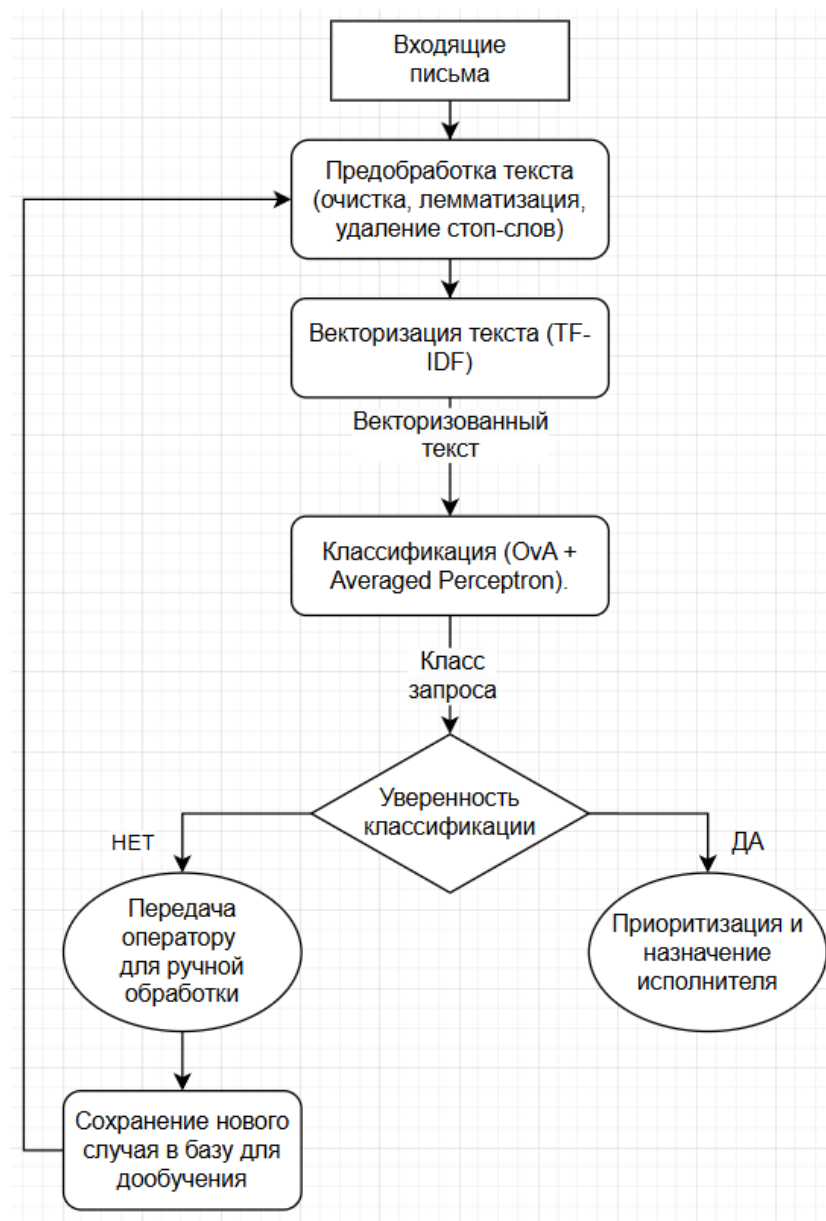


Рисунок 16 – Алгоритм предлагаемого решения

Для построения алгоритма классификации заявок были предприняты комплексные меры по настройке модели и оптимизации входных данных.

Одной из ключевых задач стало использование источника запроса для предварительного сужения категорий. Поскольку различные отделы компании (например, Бухгалтерия, Разработка, Административный отдел) имеют свою специфику запросов, исходя из того, откуда поступил запрос, можно значительно сократить количество возможных классов. Такой подход позволил минимизировать вероятность ошибок классификации и снизить сложность задачи для модели. Например, заявки от отдела Разработки чаще связаны с доступом к репозиториям или настройкой серверов, в то время как запросы Бухгалтерии касаются вопросов учёта и финансовых систем.

Обучение модели для обработки заявок в helpdesk с использованием Averaged Perceptron и стратегии One-vs-All начинается с этапа сбора данных. На этом этапе формируется исторический набор данных, ранее обработанные helpdesk, и соответствующие им метки категорий. Эти данные служат основой для обучения модели. История запросов предоставила возможность извлечь ключевые закономерности и типовые случаи. Это позволило модели не только успешно классифицировать стандартные запросы, но и улучшить точность в работе с редко встречающимися проблемами. Кроме того, исторические данные помогли определить частотные зависимости между категориями заявок и источниками, что сделало процесс классификации более адаптивным.

Затем проводится предобработка данных, включающая очистку текстов сообщений. Это включает удаление лишних символов, таких как HTML-теги, пунктуация, а также приведение текста к единому регистру. Дополнительно удаляются стоп-слова, такие как "и", "но", "это", которые не несут значимой информации для классификации. После этого выполняется лемматизация, что помогает привести слова к их базовой форме, минимизируя разнообразие словоформ.

Важным этапом оптимизации стало добавление ключевых слов и соответствующих весов в модель. Для каждого класса были выделены слова,

которые чаще всего ассоциируются с определёнными типами проблем. Эти ключевые слова служат основой для классификации текста запроса. Однако на этом этапе модель учитывает не только наличие отдельных ключевых слов, но и их "условный вес". Если определённые слова появляются в специфическом контексте, их значимость для классификации увеличивается или уменьшается. Например, слово "сеть" имеет высокий вес для "Сетевой проблемы", но если в запросе встречаются слова "домен" или "сетевая папка", то его вес для "Сетевой проблемы" снижается.

Сами ключевые слова и их вес были дополнительно связаны с общими признаками заявки, такими как длина текста, количество технических терминов и частота встречаемости определённых слов в истории заявок из конкретного источника. Эти дополнительные признаки помогли модели лучше учитывать специфику формулировок, которые используют сотрудники разных отделов. Например, короткие запросы с малым количеством ключевых слов чаще классифицируются как "Общие вопросы", в то время как технические проблемы обычно содержат больше специфики.

Следующий шаг заключается в преобразовании текста в числовую форму, пригодную для работы модели. Для этого используются методы векторизации, такие как TF-IDF (Term Frequency-Inverse Document Frequency), который учитывает значимость каждого слова в контексте корпуса данных.

Для каждой категории в рамках подхода One Versus All была построена отдельная модель Averaged Perceptron. Каждая из них обучалась на задаче бинарной классификации: "принадлежит данному классу" против "не принадлежит". Такой подход позволил учесть особенности каждой категории и снизить влияние несбалансированности данных между классами. Важной частью обучения стало обеспечение сбалансированности тренировочных данных для каждого классификатора, чтобы модели одинаково хорошо распознавали как принадлежащие, так и не принадлежащие случаи. Этот алгоритм работает итеративно, обрабатывая каждый входной вектор признаков и рассчитывая скалярное произведение весов модели и вектора

признаков. Если предсказание не соответствует истинной метке класса, веса модели обновляются с учётом ошибки. В конце обучения вычисляется усреднённый вектор весов, который делает модель более устойчивой к шуму в данных.

После обучения и настройки моделей была проведена постобработка результатов классификации. Для случаев, где уверенность предсказания была низкой, добавлены механизмы проверки на соответствие базовым правилам, таким как недопустимость определённых сочетаний категорий и источников. Это позволило минимизировать ошибки маршрутизации. Кроме того, запросы с низкой уверенностью автоматически перенаправлялись на ручную обработку, что дополнительно снизило вероятность ошибок.

3.1 Тестирование решения

Для корректного внедрения новой решения необходимо предварительно его протестировать, но перед установкой в существующую рабочую среду важно провести как эксперимент, так и апробацию решения. Эти процессы обеспечивают всестороннюю оценку эффективности программы, однако имеют разные цели и характер.

Эксперимент в контролируемой среде направлен на проверку теоретических гипотез и моделей в контролируемых условиях. Его задача — изучить, как различные факторы влияют на работу алгоритмов, выявить причинно-следственные связи, а также подтвердить или опровергнуть первоначальные предположения. Это исследование, которое позволяет оценить, насколько корректно и надёжно программа решает задачу классификации запросов на основе выбранных параметров и алгоритмов.

Апробация же необходима для оценки практической применимости программы в условиях, приближенных к реальной рабочей среде. Этот этап позволяет понять, насколько эффективно разработка будет работать на практике, когда она взаимодействует с реальными данными, системами и

пользователями. Здесь оцениваются такие показатели, как точность работы программы в реальном времени, удобство её использования для операторов и общий эффект от внедрения решения в бизнес-процессы.

Экспериментальное исследование эффективности использования машинного обучения для обработки входящих запросов включает несколько ключевых этапов, на которых будет проводиться эксперимент в контролируемой среде, апробация в условиях, приближенных к рабочей среде и оценка внедренного решения в реальных рабочих условиях. Ожидаемые результаты представлены в таблице 6:

Таблица 6 – Ожидаемые результаты до и после использования машинного обучения

Показатель	До ИИ	После ИИ	Комментарий
Среднее время обработки запроса	6 часов	3 часа	Большая часть рутинных задач будет выполняться автоматически, что сократит время обработки запросов
Ошибки в маршрутизации	20%	10	ИИ способен точнее классифицировать запросы и направлять их в нужные отделы, что снизит процент ошибок
Уровень удовлетворенности клиентов	75%	85%	Более быстрая и точная обработка запросов повысит уровень удовлетворенности клиентов
Автоматическая обработка запросов	0%	40%	-
Снижение нагрузки на операторов	-	30%	-

Отсюда можем сделать вывод, что экспериментальное исследование позволит оценить эффективность использования машинного обучения для обработки входящих запросов.

Для успешного проведения эксперимента по исследованию эффективности применения машинного обучения в обработке входящих запросов на этапе подготовки было необходимо собрать и организовать набор

данных. Основой для построения ML-моделей также стали исторические данные - 2500 запросов. Эти данные представляли собой массивы исторических запросов, поступивших в helpdesk-подразделение компании, с полной информацией о каждом запросе: тема, ключевые слова, источник (отправитель), и упоминания исполнителей. Эти параметры были выбраны как ключевые для дальнейшей классификации. Данный срез был разделен на обучающее и тестовое множества с целью обеспечения возможности тестирования модели на данных, которые она ранее не «видела». Обучающее множество включает 90% всех запросов и предназначено для обучения модели, в то время как тестовое множество состоит из оставшихся 10% и используется для проверки качества классификации, в соответствии с таблицей 7.

Таблица 7 – Разбиение входящих запросов на множества

Параметр	Значение
Обучающее множество, %	90
Тестовое множество, %	10
Метод разбиения	Случайный

Этапы обучения отображены на рисунке 17.

Для развертывания тестового стенда были использованы два сервера. На одном была развернута модель (далее ML-сервер), а на втором – почтовый сервер, на котором работал скрипт, который постепенно импортировал запросы из обучающего множества, тем самым эмулируя работу оператора. ML-сервер «слушал» почтовый сервер и обрабатывал поступающие запросы в режиме реального времени. Это позволило протестировать, как машинное обучение справляется с задачами, связанными с обработкой запросов в реальной среде.



Рисунок 17 – Этапы обучения предлагаемого решения

Для оценки эффективности модели машинного обучения в реальной среде были использованы несколько ключевых метрик. Основной метрикой для проверки качества классификации запросов была точность модели, которая измерялась на основе правильных и ошибочных классификаций запросов. Тестирование показало, что модель достигает точности классификации на уровне 92%, что соответствует ожиданиям для такой задачи, т.е. в 92% случаев алгоритм правильно классифицировал запросы и направлял их нужным инженерам. Помимо точности классификации, также измерялась скорость обработки запросов. В ходе тестирования было установлено, что среднее время обработки одного запроса с использованием машинного обучения составило 2 секунды, что значительно ниже времени, которое операторы затрачивали на ручную классификацию.

Для более детальной оценки качества модели использовались метрики полноты и точности (precision и recall). Полнота показывает, насколько

хорошо модель определяет все релевантные запросы, а точность отражает долю правильно классифицированных запросов среди всех, направленных на определенные категории. Для выбранных классов точность составила 90%, а полнота — 88%, что говорит о сбалансированной производительности модели и её способности эффективно маршрутизировать запросы. Эти метрики подтверждают, что выбранный алгоритм Averaged Perceptron в сочетании с методом One Versus All хорошо справляется с задачей многоклассовой классификации.

Также была рассчитана метрика F1-Score, которая объединяет значения точности и полноты в единый показатель. F1-Score для модели составил 89%, что является хорошим результатом для задач классификации запросов [16]. Это означает, что модель не только точна, но и достаточно чувствительна к различным категориям запросов, обеспечивая надежную маршрутизацию даже в условиях высоких требований к точности.

Результаты тестирования показали, что система успешно справляется с задачами в условиях реальной эксплуатации.

3.2 Проведение эксперимента

Эксперимент проводился в течение фиксированного периода времени, чтобы накопить достаточный объем данных для анализа и сравнительной оценки.

Для проведения эксперимента запросы были разделены на две основные группы: контрольную и экспериментальную, для объективной оценки влияния внедрения системы машинного обучения на обработку запросов по сравнению с существующим методом.

Контрольная группа. В этой группе операторы helpdesk обрабатывали запросы вручную, следуя обычным регламентам компании. Все задачи, включая классификацию и маршрутизацию запросов, выполнялись операторами на основании установленных правил и их личного опыта. Это

позволило собрать данные о времени обработки запросов, точности их маршрутизации и удовлетворенности клиентов до внедрения систем ИИ [26].

Экспериментальная группа. В этой группе была внедрена система машинного обучения для автоматической классификации и маршрутизации запросов. Алгоритмы ИИ обрабатывали входящие запросы, автоматически классифицируя их по нескольким параметрам (тема письма, ключевые слова, отправитель, упоминание исполнителя). Операторы в этой группе были задействованы только для контроля за работой системы и в случае сложных или нестандартных запросов.

Для оценивания эффективности программы в классификации необходимо собрать данные для каждого типа группировки: по теме письма, по ключевым словам, по источнику, по упоминаниям исполнителя.

После завершения эксперимента результаты работы обеих групп были тщательно проанализированы и сравнены. Сравнение включало ключевые показатели эффективности: время обработки, точность маршрутизации, уровень ошибок, а также удовлетворенность клиентов.

Для каждого типа группировки запросов система машинного обучения показывала различные уровни точности, как на этапе обучения, так и на этапе классификации. Это говорит о способности модели не только обучаться на ранее известных данных, но и правильно обрабатывать новые, ранее неизвестные запросы в соответствии с таблицей 8.

Таблица 8 – Результаты эксперимента

Группировка запросов	Результат обучения	Результат классификации
По теме	95%	93%
По ключевым словам	93%	92%
По источнику	93%	92%
По упоминаниям исполнителя	95%	93%

Анализ представленных данных позволяет заключить, что метод классификации запросов на основе машинного обучения демонстрирует устойчиво высокие результаты. Система показала высокую точность как при обучении, так и при тестовой классификации запросов, что позволяет утверждать, что данное решение способно быть применено в реальной среде helpdesk с высокой степенью доверия.

При существующем высоком уровне потока запросов проведенный эксперимент показал значительную эффективность классификации запросов. Это не только снижает нагрузку на операторов, но и позволяет ускорить обработку запросов, улучшая общую производительность отдела поддержки.

Дополнительно важно отметить, что система машинного обучения не только эффективно решает задачи маршрутизации и распределения запросов, но и снижает количество возможных ошибок, связанных с человеческим фактором [15][36]. Например, распределение запросов по ключевым словам или упоминанию исполнителя позволяет системе самостоятельно идентифицировать наиболее подходящего оператора, что значительно сокращает время обработки.

3.3 Апробация решения

Апробация нацелена на проверку практической применимости разработанного решения и обычно проводится в условиях, приближенных к рабочей среде, чтобы оценить, как система функционирует на практике и отвечает на запросы пользователей.

Подготовлена инфраструктура с клиент-серверным приложением, которое служит основой для обработки запросов в helpdesk-системе. Клиентская часть была установлена у операторов и инженеров, обеспечивая им удобный интерфейс для регистрации, распределения и обновления статусов запросов в режиме реального времени. Серверная часть, настроенная на постоянное «прослушивание» почтового сервера, автоматически

импортирует входящие запросы, поступающие через электронную почту, и передает их операторам для дальнейшей обработки. Приложение также поддерживает двусторонний обмен данными, что позволяет инженерам и операторам оперативно взаимодействовать, сокращая время на обработку и улучшая качество выполнения запросов.

В рамках апробации была организована пилотная фаза, в ходе которой небольшая группа операторов и инженеров начала активно использовать новое приложение для обработки входящих запросов. Пилотирование помогло выявить начальные проблемы и недочеты в работе системы, что позволило оперативно провести корректировки. В частности, были выявлены особенности интерфейса, требующие доработки для улучшения удобства пользователя. Также на этом этапе были учтены особенности взаимодействия с системой, которые требовали оптимизации алгоритмов маршрутизации запросов.

Одним из ключевых этапов апробации стал сбор обратной связи от пользователей системы. Это позволило выяснить, насколько интуитивно понятен интерфейс, а также насколько система отвечает на реальные потребности пользователей. Обратная связь показала, что несмотря на положительные результаты в плане ускорения обработки запросов, необходимо было улучшить функционал поиска запросов и добавление меток для более точной классификации запросов.

Далее проводился мониторинг производительности приложения в реальном времени, включая сбор статистики по ключевым метрикам, таким как время обработки запросов, количество успешно классифицированных запросов, а также уровень ошибок в маршрутизации. Важно было оценить, как новая система справляется с текущим потоком входящих запросов и как это влияет на общую производительность службы технической поддержки. На основе анализа этих метрик было принято решение о необходимости внесения корректировок в алгоритм классификации запросов, так как были

зафиксированы случаи некорректной маршрутизации некоторых запросов в первые дни эксплуатации.

Также в рамках апробации был проведен анализ нагрузки на систему при увеличении объема запросов. На этом этапе была оценена масштабируемость решения и его способность поддерживать работу при увеличении потока данных. В результате тестирования было выявлено несколько узких мест, которые могли возникнуть при увеличении нагрузки, что потребовало дополнительных усилий по оптимизации серверной части системы.

На последующем этапе апробации, после внесения исправлений и улучшений в интерфейс и алгоритмы, планируется повторное тестирование с более широкой группой пользователей. Это позволит окончательно подтвердить работоспособность решения и его готовность к полному развертыванию.

Таким образом, апробация показала, что предложенное решение имеет высокий потенциал для улучшения процесса обработки запросов в helpdesk-системе, однако требуется дальнейшая оптимизация и настройка системы с учетом полученной обратной связи и выявленных проблем.

3.4 Результаты апробации

Результаты апробации программы, основанной на машинном обучении для обработки входящих запросов в helpdesk-системе, позволили оценить её эффективность и выявить ключевые аспекты, требующие внимания. Ниже представлены основные результаты, полученные по завершении апробации.

Повысилась скорость и качество обслуживания. Использование машинного обучения для обработки запросов позволило значительно сократить время ответа, если до внедрения технологии среднее время ответа на запрос составляло 6 часов, то после оно сократилось в 2 раза, до 3 часов. Благодаря автоматической маршрутизации, которая правильно распределяет запросы, снизилось количество некорректно направленных обращений –

количество ошибок снизилось с 20% до 10%. Это привело к улучшению клиентского опыта, и доля удовлетворенных клиентов может возрасти с 75% до 85%, в соответствии с рисунком 18.

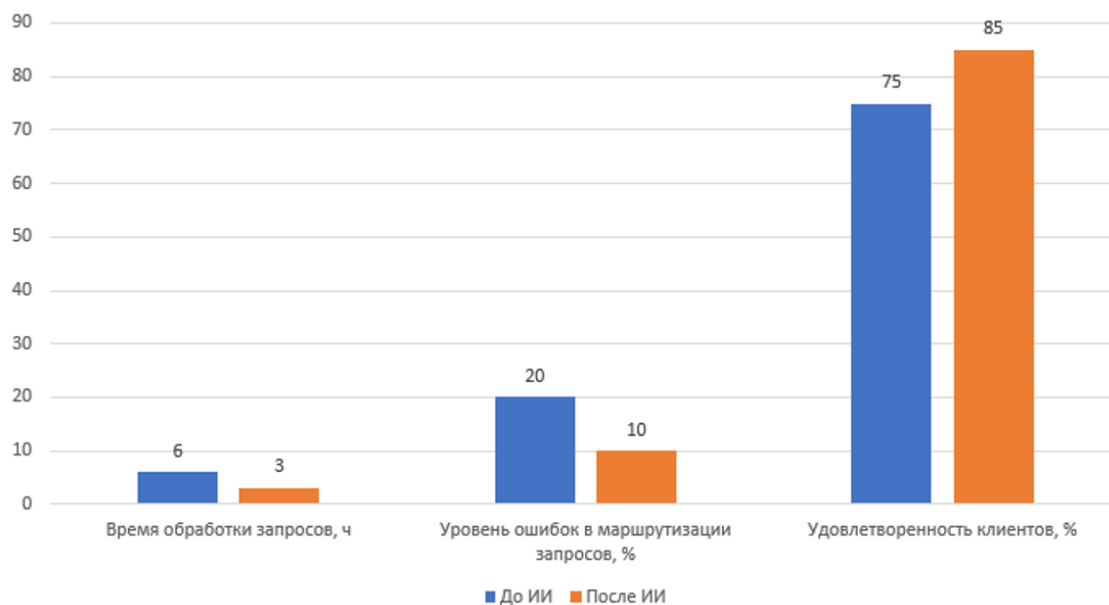


Рисунок 18 - Улучшение скорости и качества обслуживания

Снижение операционных затрат. Автоматизация процесса обработки запросов снизила необходимость в дополнительных трудовых ресурсах. До внедрения машинного обучения helpdesk подразделение могло обрабатывать до 500 запросов в месяц с участием 30 сотрудников. После - та же команда из 30 сотрудников может обрабатывать до 800 запросов в месяц, что показывает увеличение эффективности на 60% и снижает потребность в увеличении штата, как это отобразено на рисунке 19.

Повысилась гибкость и масштабируемость процессов. Машинное обучение адаптируется к росту объема запросов, позволяя компании масштабироваться без увеличения затрат на ресурсы. Например, если количество запросов выросло с 500 до 1000 в месяц за год, система может справиться с этим ростом без необходимости увеличения штата сотрудников. Кроме того, система может самостоятельно обучаться и совершенствоваться,

обрабатывая новые типы запросов или адаптируясь к изменениям в требованиях клиентов. Это повышает гибкость бизнес-процессов и уменьшает зависимость от человеческого фактора, в соответствии с рисунком 20.




Рисунок 19 - Снижение операционных затрат




Рисунок 20 - Повышение гибкости и масштабируемости процессов

Снижение нагрузки на сотрудников. Большая часть рутинных задач автоматизировалась, что позволило сотрудникам фокусироваться на более сложных и креативных задачах, освободило время для решения нестандартных задач. Изначально сотрудники тратили до 70% своего времени на классификацию и приоритезацию запросов, а после данный показатель сократился до 30%. Это снизило уровень стресса и повысило общую производительность сотрудников, в соответствии с рисунком 21.




Рисунок 21 - Снижение нагрузки на сотрудников

Рост конкурентоспособности компании. Использование передовых технологий, таких как машинное обучение, помогает компании стать более конкурентоспособной. Например, если среднее время реакции на запросы у конкурентов составляет 3 часа, компания может сократить это время до 1,5 часов, что выделяет её на фоне конкурентов. Более того, автоматизация повышает скорость реагирования на запросы и сокращает количество ошибок, что может увеличить лояльность клиентов на 15-20% и улучшить позиции компании на рынке, в соответствии с рисунком 22.

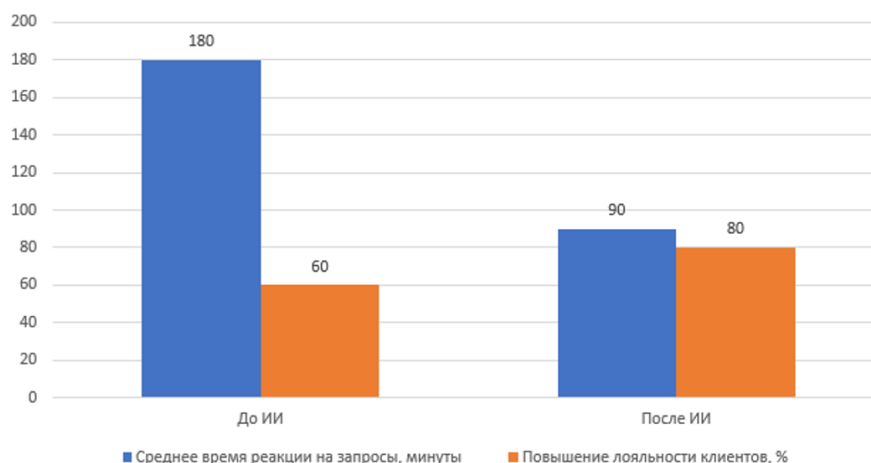


Рисунок 22 - Рост конкурентоспособности компании

Возможность прогнозирование и предотвращение потенциальных проблем. Исторические данные могут быть проанализированы системой, и она может предсказывать пиковое увеличение количества запросов. К примеру, если в определенные месяцы количество запросов стабильно увеличивается на 25%, система может заранее подготовить рекомендации по распределению ресурсов и предотвращению перегрузки. Это поможет снизить риски сбоев в обслуживании клиентов и поддержать высокий уровень сервиса даже в пиковые периоды, как отражено на рисунке 23.

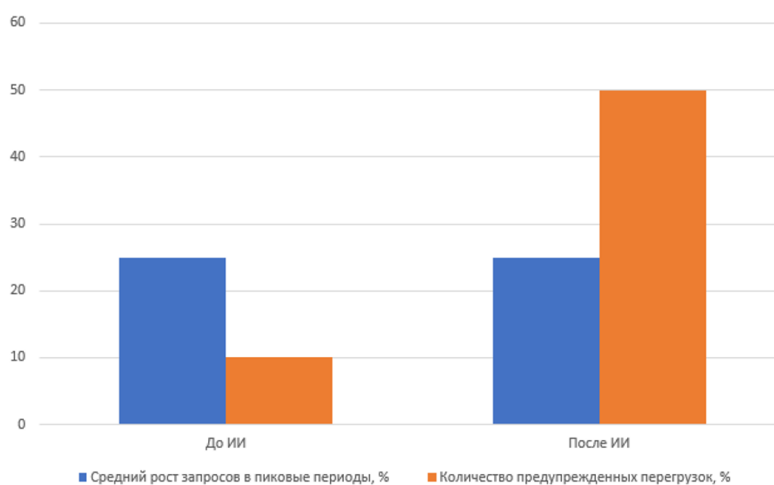


Рисунок 23 - Прогнозирование и предотвращение потенциальных проблем

При существующем высоком уровне потока запросов проведенный эксперимент показал высокую эффективность.

В ходе апробации было собрано несколько типов обратной связи, которые играют ключевую роль в оценке качества и практичности работы разработанного решения. В частности, отзывы пользователей касались как функциональных аспектов системы, так и удобства её использования. После внедрения клиент-серверного приложения операторы и инженеры начали активно работать с интерфейсом, что дало возможность выявить слабые места в его дизайне и функциональности.

Пользователи отмечали, что интерфейс был в целом интуитивно понятен, однако некоторые функции, такие как фильтрация и поиск запросов, требовали доработки. Это стало очевидным при обработке большого числа запросов в реальном времени, когда требовалась быстрая локализация запросов по категориям и приоритетам. Некоторые операторы сообщали, что из-за недостаточной гибкости фильтрации не всегда удавалось быстро находить нужные запросы, что замедляло процесс их обработки.

Кроме того, в ходе апробации было выявлено, что система классификации запросов, основанная на алгоритмах машинного обучения, иногда неправильно распределяла запросы по категориям. Это привело к необходимости доработки алгоритмов маршрутизации, а также улучшения обучающей выборки для повышения точности классификации.

Обратная связь также касалась улучшения взаимодействия между клиентами и операторами. Было предложено добавить более четкие уведомления о статусах запросов, что позволит операторам быстрее реагировать на изменения ситуации. Также пользователи предложили внедрить функцию сортировки запросов по степени срочности, что ускорит процесс обработки критичных запросов.

Кроме того, была собрана обратная связь по работе серверной части приложения, касающаяся производительности системы при большом объеме входящих запросов. Несмотря на положительные результаты в тестах с низкой

нагрузкой, при увеличении числа запросов наблюдались небольшие задержки в обработке, что потребовало дополнительной оптимизации.

Обратная связь помогла не только выявить технические и функциональные проблемы, но и уточнить предпочтения пользователей относительно интерфейса и взаимодействия с системой. Все собранные данные были систематизированы и учтены при следующем этапе разработки, что позволило улучшить интерфейс, доработать алгоритмы классификации и повысить производительность системы.

Таким образом, результатами апробации стали не только количественные данные о производительности, но и качественная информация о пользователях, которая позволила усовершенствовать систему. В дальнейшем планируется продолжить тестирование и внедрять улучшения, основываясь на полученной обратной связи, что обеспечит успешное внедрение системы в полноценную эксплуатацию.

Выводы по третьему разделу.

В данном разделе представлены результаты эксперимента и апробации предложенной системы на основе методов машинного обучения для классификации и обработки входящих запросов в helpdesk-среде. Анализ полученных данных показал высокую точность и стабильность работы системы при классификации запросов как в обучающей, так и в тестовой выборках. Это свидетельствует о её готовности к практическому применению с высокой степенью достоверности.

Апробация системы позволила выявить её преимущества: повышение скорости и качества обслуживания, снижение операционных затрат, улучшение гибкости и масштабируемости, уменьшение нагрузки на сотрудников, поддержка управленческих решений, рост конкурентоспособности компании, а также возможность прогнозирования и предотвращения потенциальных проблем.

Заключение

Основные научные результаты диссертации.

В ходе исследования достигнуты ключевые научные результаты, направленные на решение проблемы автоматизации обработки запросов в helpdesk-подразделениях ИТ-компаний. Основной целью работы было обоснование эффективности машинного обучения в автоматической классификации и распределении запросов. Проведенные эксперименты подтвердили гипотезу о том, что внедрение алгоритмов машинного обучения, таких как Averaged Perceptron с методом One Versus All для многоклассовой классификации, позволяет существенно сократить время обработки и повысить точность распределения запросов.

Эксперимент показал высокую точность классификации: по теме письма — 93%, по ключевым словам — 92%, по источнику — 92%, по упоминаниям исполнителя — 93%. Эти результаты демонстрируют, что предложенная модель способна точно определять принадлежность запросов к определённым категориям, что значительно облегчает их маршрутизацию.

Увеличилась скорость обработки запросов. До внедрения модели среднее время ответа на запрос составляло 6 часов. После внедрения машинного обучения этот показатель сократился до 3 часов, что позволило повысить скорость реакции на запросы пользователей в два раза.

Оптимизация затрат и повышение эффективности. Внедрение модели увеличило пропускную способность подразделения: при сохранении того же состава команды (30 сотрудников) количество обработанных запросов в месяц возросло с 500 до 800. Время, которое сотрудники тратили на ручную классификацию запросов, снизилось с 70% до 30%, что позволяет направить ресурсы на выполнение более сложных задач, требующих участия человека.

Эти результаты не только подтверждают целесообразность использования машинного обучения в helpdesk-подразделениях, но и обеспечивают теоретический вклад в методологию обработки

слабоструктурированных текстовых данных, поскольку демонстрируют эффективность использования алгоритма Averaged Perceptron для классификации запросов.

Рекомендации по практическому применению результатов.

Внедрение разработанного решения в helpdesk-подразделениях IT-компаний и применение модели Averaged Perceptron с методом One Versus All позволяет повысить производительность отдела, снизить ошибки в маршрутизации и повысить удовлетворенность клиентов. В условиях интенсивного информационного потока это решение оптимизирует рабочий процесс и снижает нагрузку на первую линию поддержки.

Экономический эффект от внедрения: за счет повышения пропускной способности и уменьшения времени на обработку запросов предложенное решение снижает операционные расходы компании. Эти факторы способствуют улучшению клиентского опыта, повышая уровень удовлетворенности с 75% до 85%.

Перспективность дальнейшего исследования и развития - для улучшения модели рекомендуется дальнейшая интеграция более сложных алгоритмов, таких как нейронные сети и алгоритмы глубокого обучения, что позволит учитывать ещё более сложные зависимости и повышать точность классификации в условиях большого объема и разнообразия запросов.

Таким образом, достигнутые в исследовании результаты подтверждают эффективность разработанного подхода и его значимость как для практической, так и для научной сферы. Данная работа представляет собой вклад в развитие методов машинного обучения для анализа и классификации текстовых данных, создавая методологическую базу для оптимизации работы подразделений технической поддержки и повышения их конкурентоспособности.

Список используемой литературы

1. Алнафра, И. Применение методов машинного обучения в системе управления интеллектуальной собственностью на основе технологии блокчейн / И. Алнафра, А.С. Николаев, Е.Л. Богданова // Вестник Саратовского государственного социально-экономического университета. – 2019. – № 2 – С. 9-14.
2. Анализ данных и прогнозирование [Электронный ресурс] / URL: <https://v8.1c.ru/platforma/analiz-dannykh-i-prognozirovanie/> (дата обращения 15.06.21)
3. Бабуцкий, В.А. Методы и средства извлечения ключевых слов в задаче автоматической идентификации потенциально опасных текстов в условиях неопределенности их тематической принадлежности // В.А. Бабуцкий, И.Д. Сидоров. – Успехи современной науки. – Т.1, № 12, 2017. – С. 54–59.
4. Барахнин, В.Б. Автоматизированная классификация русских поэтических текстов по жанрам и стилям // В.Б. Барахнин, О.Ю. Кожемякина, И.С. Пастушков, Е.В. Рычкова. – Вестник Новосибирского государственного университета. Серия: Лингвистика и межкультурная коммуникация. – Т.15, № 3, 2017. – С. 13–23.
5. Батура, Т.В. Методы автоматической классификации текстов // Т.В. Батура. – Программные продукты и системы. – Т. 30, № 1, 2017. – С.85–99.
6. Большакова Е.И. Автоматическая обработка текстов на естественном языке и анализ данных: учеб. пособие / Е.И. Большакова, К.В. Воронцов, Н.Э. Ефремова, Э.С. Клышинский, Н.В. Лукашевич, А.С. Сапин – М.: Изд-во НИУ ВШЭ, 2017. – 269 с.
7. Варшавский П.Р. Реализация программных средств для классификации данных на основе аппарата сверточных нейронных сетей и прецедентного подхода // П.Р. Варшавский, А.В. Кожевников. – Программные продукты и системы, № 4, 2020. – С. 591-598.

8. Гаврилова, Т. А. Инженерия знаний. Модели и методы: учебник / Т.А. Гаврилова, Д.В. Кудрявцев, Д.И. Муромцев. - СПб. : Лань, 2016. - 324с.
9. Дадян, Э.Г. Разработка бизнес-приложений на платформе «1С:Предприятие»: учеб. пособие / Э.Г. Дадян. – М.: ИНФРА-М, 2019. – 306 с.
10. Кафтанников, И. Л. Проблемы формирования обучающей выборки в задачах машинного обучения / И. Л. Кафтанников, А. В. Парасич // Вестник Южно-Уральского государственного университета. Серия: Компьютерные технологии, управление, радиоэлектроника. – 2016. – № 3. – С. 15-24.
11. Кашницкий, Ю.С. Ансамблевый метод машинного обучения, основанный на рекомендации классификаторов // Ю.С. Кашницкий, Д.И. Игнатов. – Интеллектуальные системы. Теория и приложения. – Т.19, № 4, 2015.– С. 37-55.
12. Клячкин, В.Н. Выбор метода бинарной классификации при технической диагностике с применением машинного обучения / В.Н. Клячкин, Ю.Е. Кувайскова, Д.А. Жуков. – Известия Самарского научного центра Российской академии наук, т. 20, № 4(3), 2018. – С.494-497.
13. Клячкин, В.Н. Прогнозирование состояния технического объекта с применением методов машинного обучения // В.Н. Клячкин, Д.А. Жуков. – Программные продукты и системы. – Т.32, №2, 2019. – С. 244–250.
14. Комарова, А. В. Метод автоматизированного извлечения адресов из неструктурированных текстов // А.В. Комарова, А.А. Менщиков, А.В. Полев, Ю.А. Гатчин. – International Journal of Open Information Technologies. – Т.5, № 11, 2017. – С. 21–26.
15. Кораблев, А. Ю. Машинное обучение в бизнесе / А. Ю. Кораблев, Р. Б. Булатов // Азимут научных исследований: экономика и управление. – 2018. – Т. 7, № 2. – С. 68-72.
16. Корнина, А. Е. Машинное обучение и нейронные сети в бизнесе // А. Е. Корнина. – Хроноэкономика. – 2018. – № 2. – С. 111-115.

17. Коротеев, М. В. Обзор некоторых современных тенденций в технологии машинного обучения / М. В. Коротеев // E-Management. – 2018. – Т. 1, № 1. – С. 26-35.

18. Котельников Е.В. Методология интеллектуального анализа мнений при обработке текстовой информации на основе правдоподобного вывода / ДИССЕРТАЦИЯ на соискание уч. степени д.т.н. – Нижний Новгород – 2019. – 329 с.

19. Кошевой, Д.О. Рассмотрение возможностей бизнес-аналитики в 1С: Предприятии 8.3 / Д.О. Кошевой: сб. статей и тезисов, ГАОУ ВО МГПУ. – М., 2020. – Т. 2. – С. 167-168.

20. Краснянский, М.Н. Сравнительный анализ методов машинного обучения для решения задачи классификации документов научно-образовательного учреждения / М.Н. Краснянский, А.Д. Обухов, Е.М. Соломатина, А.А. Воякина. - Вестник ВГУ, серия: системный анализ и информационные технологии, № 3, 2018. – С. 173-182.

21. Кузнецов, И.А. Методы и алгоритмы машинного обучения для предобработки и классификации слабоструктурированных текстовых данных в научных рекомендательных системах / И.А. Кузнецов. – АВТОРЕФЕРАТ диссертации на соискание ученой степени к.т.н. – Москва – 2019. – 26 с.

22. Ланге, М.М. О теоретико-информационной модели классификации данных // М.М. Ланге, А.М. Ланге – Машинное обучение и анализ данных, № 4(3), 2018. – С. 165-179.

23. Ларин, с. Н. Особенности развития технологий искусственного интеллекта / С. Н. Ларин, Н. А. Соколов, Л. И. Герасимова // Экономические исследования и разработки. – 2019. – № 6. – С. 81-92.

24. Лобин, М. А. Машинное обучение в экономике / М. А. Лобин, И. А. Филиппова // Вестник УлГТУ. – 2019. – № 3. – С. 68-71.

25. Лунев, К.И. Особенности применения машинного обучения для классификации текстовых документов // К.И. Лунев. – Научные записки НГУЭУ. Выпуск 2, 2020. – С.30-32.

26. Маликов, А.В. Использование моделей машинного обучения для прогнозирования количества электронных транзакций / А. В. Маликов, Д. М. Агаджанян, П. П. Тарасевич // Современная наука и инновации. – 2018. – № 4. – С. 45-55.

27. Нгуен, М. Т. Тестирование методов машинного обучения в задаче классификации http запросов с применением технологии tf-idf / М. Т. Нгуен // Вестник Воронежского государственного университета. Серия: Системный анализ и информационные технологии. – 2019. – № 4. – С. 119-131.

28. Прохорова, М.М. Основные направления совершенствования методики статистического анализа цифровой экономики // М.М. Прохорова. – Вестник Евразийской науки, 2020 №5, URL: <https://esj.today/PDF/50ECVN520.pdf> (дата обращения 15.06.21).

29. Ракитский, А.А. Методы машинного обучения: учебно-методическое пособие / А.А. Ракитский. – Новосибирск: Сибирский государственный университет телекоммуникаций и информатики, 2018. – 32 с.

30. Соловьев, В.И. Прикладные задачи машинного обучения в экономике и финансах: Практический курс с применением технологий Microsoft Azure ML и соревнованиями на платформе Kaggle // В.И. Соловьев. – М.: КНОРУС, 2018. – 324 с.

31. Стрелец, А.И. Методы классификации текстовых данных по темам / А.И. Стрелец, В.С. Иванников, А.А. Орлов, А.В. Атавина. – Международный журнал гуманитарных и естественных наук. Т.6-1, 2019. – С.74-76.

32. Суворов, Р.Е. Активное машинное обучение в задаче извлечения информации из научных текстов / Р.Е. Суворов, А.О. Шелманов, М.А. Каменская, И.В. Смирнов. – Искусственный интеллект и принятие решений, №4, 2017. – С.40-52.

33. Юрочкин, А. Г. Проблемы машинного обучения / А. Г. Юрочкин, Н. А. Коростелева // Вестник Воронежского института высоких технологий. – 2020. – № 1. – С. 49-51.

34. Abadi M. TensorFlow: A System for Large-Scale Machine Learning // OSDI. — T.16, 2016. – C. 265–283.
35. Bijalwan V. KNN based machine learning approach for text and document mining // International Journal of Database Theory and Application. — T.7, № 1, 2014. – C. 61-70.
36. Dekhtyar A., Fong V. RE Data Challenge: Requirements Identification with Word2Vec and TensorFlow //Requirements Engineering Conference, 2017. – C. 484–489.
37. Jun S., Park S.S., Jang D.S. Document clustering method using dimension reduction and support vector clustering to overcome sparseness // Expert Systems with Applications. – T.41, № 7, 2014. – C. 3204–3212.
38. Krasnyanskiy M.N., Ostroukh A.V., Karpushkin S.V., Obukhov A.D. Algorithm for Structural and Parametric Synthesis of Electronic Document Management System of Research and Education Institution / Journal of Applied Sciences. – Vol. 16, No 7, 2016. – P. 332–337.
39. Lilleberg J., Zhu Y., Zhang Y. Support vector machines and word2vec for text classification with semantic features // Cognitive Informatics & Cognitive Computing. – 2015. – C. 136–140.
40. Lucchese C. et al. Quickscore: A fast algorithm to rank documents with additive ensembles of regression trees // Proceedings of the 38th International ACM SIGIR Conference on Research and Development in Information Retrieval. – 2015. – C. 73–82.
41. Pliakos K., Geurts P., Vens C. Global multi-output decision trees for interaction prediction // Machine Learning. – 2018. – C. 1–25.
42. Wu X. et al. Top 10 algorithms in data mining //Knowledge and information systems. – T.14, № 1, 2008 – C. 1–37.