

Министерство науки и высшего образования Российской Федерации
Федеральное государственное бюджетное образовательное учреждение
высшего образования
АМУРСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
(ФГБОУ ВО «АмГУ»)

Институт компьютерных и инженерных наук
Кафедра информационных и управляющих систем
Направление подготовки 09.04.04 – Программная инженерия
Направленность (профиль) образовательной программы Управление разработкой программного обеспечения

ДОПУСТИТЬ К ЗАЩИТЕ
Зав. кафедрой

_____ А.В. Бушманов
«__» _____ 2025 г.

МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ

на тему: Разработка приложения синхронного перевода речи с применением AR-технологий и машинного обучения

Исполнитель студент группы 3105-ом1	_____	В.А. Чистохин
	(подпись, дата)	
Руководитель доцент, канд. физ. - мат. наук	_____	В.В. Еремина
	(подпись, дата)	
Руководитель научного содержания программы магистратуры профессор, доктор техн. наук	_____	И.Е. Еремин
	(подпись, дата)	
Нормоконтроль инженер	_____	В.Н. Адаменко
	(подпись, дата)	
Рецензент доцент, канд. техн. наук	_____	С.Г. Самохвалова
	(подпись, дата)	

Министерство науки и высшего образования Российской Федерации
Федеральное государственное бюджетное образовательное учреждение
высшего образования
АМУРСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
(ФГБОУ ВО «АмГУ»)

Институт компьютерных и инженерных наук
Кафедра информационных и управляющих систем

УТВЕРЖДАЮ
Зав. кафедрой
_____ А.В. Бушманов
«___» _____ 2025 г.

З А Д А Н И Е

К выпускной квалификационной работе студента группы 3105-ом1

Чистохина Владислава Анатольевича

1. Тема магистерской диссертации: Разработка приложения синхронного перевода речи, с применением AR-технологий и машинного обучения

(Утверждено приказом от 06.03.2025 № 632-уч)

2. Срок сдачи студентом законченной работы (проекта): 10.06.2025

3. Исходные данные к магистерской диссертации: научные публикации, документация по библиотекам Python и Kotlin, учебная литература

4. Содержание магистерской диссертации (перечень подлежащих разработке вопросов): анализ синхронного и машинного перевода, разработка алгоритмического и программного решения

5. Перечень материалов приложения (наличие чертежей, таблиц, графиков, схем, программных продуктов, иллюстративного материала и т.п.): _____

6. Рецензент магистерской диссертации: Самохвалова С. Г.,
доцент, канд. техн. наук

7. Дата выдачи задания: 29.01.2025

Руководитель выпускной квалификационной работы: В.В. Еремина,
доцент, канд. физ. - мат. наук

(фамилия, имя, отчество, должность, уч. степень, уч. звание)

Заявление принял к исполнению: _____

РЕФЕРАТ

Магистерская диссертация содержит 85 с., 19 рисунков, 6 таблиц, 52 источника.

МОБИЛЬНОЕ ПРИЛОЖЕНИЕ, КЛИЕНТ-СЕРВЕРНАЯ АРХИТЕКТУРА, PYTHON, МАШИННОЕ ОБУЧЕНИЕ, AR,

Цель данной работы — разработать AR/ML-приложение для синхронного перевода речи, обеспечивающее высокую скорость и точность перевода при удобном взаимодействии с пользователем.

Задачи магистерской диссертации:

- Изучить современные подходы и технологии, применяемые в задачах синхронного перевода речи.
- Проанализировать возможность интеграции дополненной реальности и методов машинного обучения в задачи перевода речи.
- Сформулировать архитектуру системы для синхронного перевода речи с использованием AR и ML.
- Реализовать ПО для синхронного перевода речи с визуализацией в AR, оценить его производительность и точность, выявить ограничения и наметить пути дальнейшего развития.

Разработка приложения синхронного перевода речи основана на применении методов обработки естественного языка и технологий дополненной реальности. На входе система принимает аудиопоток, преобразует его в текст с помощью алгоритмов автоматического распознавания, выполняет перевод с использованием моделей машинного обучения, таких как трансформеры, и визуализирует перевод в реальном времени с использованием AR-технологий.

ОПРЕДЕЛЕНИЯ, ОБОЗНАЧЕНИЯ И СОКРАЩЕНИЯ

AR (Augmented Reality) — дополненная реальность, технология, которая накладывает виртуальные элементы на реальный мир с помощью устройств (например, смартфонов, очков AR).

ASR (Automatic Speech Recognition) — автоматическое распознавание речи, технология преобразования устной речи в текст.

ML (Machine Learning) — машинное обучение, раздел искусственного интеллекта, посвящённый созданию алгоритмов, способных обучаться на данных.

NLP (Natural Language Processing) — обработка естественного языка, область искусственного интеллекта, занимающаяся взаимодействием компьютеров и человеческого языка.

S2ST (Speech-to-Speech Translation) — перевод речи в речь, процесс преобразования устной речи на одном языке в устную речь на другом языке.

TTS (Text-to-Speech) — синтез речи, технология преобразования текста в устную речь.

API (Application Programming Interface) — интерфейс программирования приложений, набор инструментов и протоколов для взаимодействия между программными компонентами.

CNN (Convolutional Neural Network) — сверточная нейронная сеть, тип нейронной сети, используемый для обработки изображений и других данных с пространственной структурой.

RNN (Recurrent Neural Network) — рекуррентная нейронная сеть, тип нейронной сети, используемый для обработки последовательных данных, таких как речь или текст.

BLEU (Bilingual Evaluation Understudy) — метрика оценки качества машинного перевода, основанная на сравнении с эталонными переводами.

WER (Word Error Rate) — уровень ошибок по словам, метрика оценки качества распознавания речи.

UI (User Interface) — пользовательский интерфейс, часть приложения, с которой взаимодействует пользователь.

UX (User Experience) — пользовательский опыт, восприятие и удобство использования приложения с точки зрения пользователя.

SDK (Software Development Kit) — набор инструментов для разработки программного обеспечения.

DL (Deep Learning) — глубокое обучение, подраздел машинного обучения, использующий многослойные нейронные сети.

ARCore — платформа для разработки приложений дополненной реальности от Google.

STT (Speech-to-Text) — преобразование речи в текст.

MT (Machine Translation) — машинный перевод, автоматический перевод текста или речи с одного языка на другой.

E2E (End-to-End) — сквозной подход, при котором система обучается выполнять задачу от начала до конца без промежуточных этапов.

SLAM (Simultaneous Localization and Mapping) — одновременная локализация и построение карты, технология, используемая в AR для определения положения устройства в пространстве.

СОДЕРЖАНИЕ

Введение	8
1 Общая характеристика предметной области и объекта исследования	10
1.1 Анализ предметной области	10
1.2 Объект исследования	11
1.3 Актуальность проводимого исследования	12
1.4 Существующие методы решения	13
1.5 Анализ готового программного обеспечения в области машинного обучения их преимущества и недостатки	16
1.6 Особенности интеграции AR-технологий и машинного обучения	22
1.7 Ограничения и требования для мобильных приложений	23
1.8 Определение основных направлений разработки	25
2 Алгоритмическое решение исследуемой задачи и выбор программно-технической платформы	27
2.1 Алгоритмическая модель приложения синхронного перевода речи с применением AR-технологий и машинного обучения	27
2.2 Профильное программное обеспечение для реализации клиента и сервера	35
2.2.1 Серверная часть	35
2.2.2 Клиентская часть (Android)	36
2.3 Синтез алгоритма обработки речевых данных	38
2.4 Интеграция технологий машинного обучения и дополненной реальности	40
2.5 Системные требования	42
2.6 Реализация клиент-серверного взаимодействия	44
2.7 Определение основных направлений разработки	45
3 Программная реализация предлагаемого алгоритма решения задачи	47

3.1 Основные этапы практической разработки программного продукта	47
3.1.1 Модель жизненного цикла программного обеспечения	47
3.1.2 Состав работ по созданию системы синхронного перевода речи	48
3.1.3 Функциональные требования к системе	51
3.2 Практическая реализация программы	54
3.2.1 Архитектура разработанной системы	54
3.2.2 ER-модель данных	61
3.2.3 Механизм захвата и передачи данных между клиентом и сервером	63
3.2.4 Серверная обработка изображения, перевода и AR-визуализации	66
3.2.5 Архитектура асинхронного взаимодействия на Kotlin и FastAPI	69
3.2.6 Интерфейс пользователя и отображение перевода в AR-сцене	71
3.2.7 Пример пользовательского сценария работы системы	72
3.2.8 Оценка производительности и сценарии масштабирования	79
Заключение	80
Библиографический список	81

ВВЕДЕНИЕ

Современная эпоха характеризуется активной глобализацией и ростом межкультурного взаимодействия, в результате чего потребность в оперативной и качественной межъязыковой коммуникации стремительно возрастает. Языковой барьер по-прежнему остаётся одной из ключевых проблем в международном общении — как в повседневной жизни, так и в профессиональной среде, включая образование, бизнес, туризм, здравоохранение и международную дипломатию.

Традиционные решения для преодоления языковых препятствий, включая услуги профессиональных переводчиков или использование стандартных мобильных и десктопных переводчиков, обладают рядом ограничений. К ним относятся:

- высокая зависимость от подключения к интернету;
- задержки в передаче информации;
- неудобный пользовательский интерфейс;
- ограниченные возможности работы в реальном времени и офлайн.

В ответ на эти вызовы активно развиваются технологии дополненной реальности (AR) и машинного обучения (ML), открывающие новые возможности в сфере автоматического перевода речи. AR позволяет не просто предоставить текстовый результат перевода, но и визуализировать его прямо в поле зрения пользователя — на экране смартфона или через AR-устройства, такие как очки или шлемы дополненной реальности. Это существенно упрощает восприятие информации, снижает когнитивную нагрузку и делает процесс перевода более естественным и интуитивным.

Одновременно с этим достижения в области искусственного интеллекта, особенно в таких направлениях как автоматическое распознавание речи (ASR) и нейронный машинный перевод (NMT), позволяют достигать высокой точности распознавания даже в условиях фонового шума, акцентов и спонтанной речи. В дополнение, модели оптического распознавания текста (OCR), основанные на

ONNX-совместимых архитектурах, позволяют интегрировать обработку визуального текста, например, из изображений с камеры.

Таким образом, разработка системы синхронного перевода речи с визуализацией результата через дополненную реальность, опирающейся на машинное обучение, представляет собой перспективное направление, обладающее как теоретической значимостью, так и широкой областью практического применения.

Актуальность исследования обусловлена следующими задачами:

- обеспечение точного и максимально оперативного перевода речи в реальном времени;
- реализация интуитивно понятного и эргономичного пользовательского интерфейса;
- адаптация к различным акустическим условиям, акцентам и языковым конструкциям;
- визуализация перевода с помощью дополненной реальности для повышения эффективности восприятия информации.

Объект исследования:

- Процесс автоматического синхронного перевода устной речи с использованием технологий дополненной реальности и методов машинного обучения.

Цель исследования:

- Разработка мобильного программного решения, способного выполнять синхронный перевод речи с последующей визуализацией перевода в пространстве в формате AR, с применением современных моделей ASR, NMT и OCR.

Реализация такого решения позволит устранить ключевые недостатки существующих систем перевода и создаст новую парадигму взаимодействия пользователей в многоязычной среде.

1 ОБЩАЯ ХАРАКТЕРИСТИКА ПРЕДМЕТНОЙ ОБЛАСТИ И ОБЪЕКТА ИССЛЕДОВАНИЯ

1.1 Анализ предметной области

Синхронный перевод речи является важным направлением в развитии современных технологий, особенно в условиях глобализации и растущей потребности в коммуникации между людьми, говорящими на разных языках. Эта задача требует высокой скорости обработки информации и точности перевода, что делает её одной из наиболее сложных в области искусственного интеллекта.

Развитие технологий распознавания речи (ASR, Automatic Speech Recognition) и машинного перевода (MT, Machine Translation) значительно ускорило прогресс в создании систем синхронного перевода. Такие системы работают в реальном времени, преобразуя устную речь на одном языке в текст, переводя его на другой язык и озвучивая результат.

Искусственный интеллект и глубокое обучение. Современные системы используют нейронные сети, включая рекуррентные (RNN) и трансформеры, такие как модели BERT или GPT. Эти алгоритмы обеспечивают высокую точность распознавания речи и контекстного перевода.

Улучшение качества перевода. Используются подходы, основанные на обработке больших объемов данных и адаптации систем к специфике контекста. Это позволяет учитывать особенности разговорной речи, диалекты и интонации.

Облачные решения и мобильные платформы. Технологии синхронного перевода интегрируются в облачные сервисы, что делает их доступными для мобильных приложений и устройств.

Несмотря на значительные достижения, синхронный перевод речи остаётся сложной задачей из-за:

- высокой вариативности акцентов, темпа речи и фонового шума;
- необходимости точного перевода идиом, метафор и других сложных языковых конструкций;

– ограничений вычислительных ресурсов, особенно для работы на мобильных устройствах или в режиме оффлайн.

1.2 Объект исследования

Объектом исследования является разрабатываемая программная система, предназначенная для синхронного перевода устной речи и текста с последующей визуализацией переведённого результата в дополненной реальности (AR). Система реализована в виде комплексного программного решения, состоящего из двух основных частей:

– Мобильное клиентское приложение на платформе Android, которое обеспечивает предварительное автономное распознавание входного аудио-сигнала, а также отображение пользователю перевода с помощью аппаратных вычислительных средств и предзагруженных моделей машинного перевода.

– Серверное приложение (backend), реализованное на Python, которое выполняет ресурсоёмкие операции обработки изображений, перевода и наложения AR-текста с помощью передовых нейросетевых моделей.

Разрабатываемая система интегрирует следующие ключевые технологии:

– Автоматическое распознавание речи (ASR), обеспечивающее преобразование устной речи пользователя в текстовую форму.

– Нейросетевой машинный перевод (NMT). Данная технология позволяет точно и контекстно корректно переводить текст с одного языка на другой, учитывая специфику различных языковых пар и диалектов.

– Оптическое распознавание текста (OCR), используемое для извлечения и распознавания текста из изображений, полученных с камеры мобильного устройства. Для этого применяется PaddleOCR, многоязычная нейросетевая система с высокой эффективностью распознавания.

– Визуализация перевода в дополненной реальности. Это позволяет отображать результаты перевода прямо в поле зрения пользователя, улучшая восприятие и снижая когнитивную нагрузку.

Особенностью предлагаемой системы является сбалансированное разделение нагрузки между мобильным клиентом и серверной частью:

На стороне клиента осуществляется предварительная обработка входных данных: захват и первичная обработка аудиосигнала, локальное распознавание простых речевых и текстовых элементов, а также формирование запроса на сервер.

На серверной стороне происходит основная обработка данных, включая применение сложных нейросетевых ONNX-моделей. В частности, сервер выполняет задачи классификации, детекции и распознавания текста с изображений, а также перевод текста и формирование изображений с наложенным AR-контентом.

Такой подход позволяет обеспечить высокую производительность, минимальную задержку и оптимальное использование аппаратных ресурсов мобильных устройств, сохраняя при этом точность и качество перевода.

1.3 Актуальность проводимого исследования

Актуальность разработки приложения синхронного перевода речи с ML и AR обоснована следующими техническими преимуществами:

- Разгрузка клиентского устройства:
 - Локальная предварительная фильтрация и буферизация аудио/изображений позволяют снизить требования к CPU/NPU смартфона.
 - Основные ML-задачи (глубокое ASR, NMT, OCR, AR-рендеринг) выполняются на сервере с GPU/ONNX-ускорением, гарантируя стабильную производительность на слабых устройствах.
- Низкая и предсказуемая задержка:
 - Передача лишь ключевых фреймов и сжатых данных по WebSocket уменьшает сетевой трафик.
 - Серверный конвейер ASR→NMT→AR генерирует готовый AR-кадр одной итерацией, минимизируя раунд-трипы.

- Гибридная работа и устойчивость:
 - В офлайн-режиме мобильный клиент использует облегчённые ONNX-модели для критичных функций (распознавания речи, OCR), сохраняя базовую работоспособность без связи.
 - При восстановлении соединения система автоматически переключается на серверный режим для повышения качества перевода.
- Масштабируемость и простота сопровождения:
 - Микросервисная архитектура (ASR, NMT, OCR, AR) позволяет горизонтально масштабировать узкие места.
 - Централизованная загрузка и обновление ML-моделей на сервере исключает необходимость частых обновлений клиентского ПО.
- Интуитивный AR-интерфейс:
 - Прямая визуализация перевода в поле зрения избавляет пользователя от переключения между приложениями или аудиовыводом.
 - Координаты и стили текста задаются сервером, что упрощает синхронизацию и гарантирует единообразие отображения.

Эти факторы делают разработку гибридного AR+ML-приложения для синхронного перевода речи технически оправданной и перспективной в условиях растущих требований к скорости, качеству и надёжности перевода.

1.4 Существующие методы решения

При анализе архитектур мобильных приложений для синхронного перевода речи с ML и AR можно выделить несколько устоявшихся приёмов и технологий:

- Разгрузка клиентского устройства:
 - Локальная фильтрация и буферизация аудио- и видеопотока выполняется на сервере, что снижает нагрузку на CPU/NPU смартфона.
 - Серверный ML-конвейер на GPU/ONNX гарантирует высокую пропускную способность и стабильность даже на бюджетных устройствах.
- Минимизация задержек (latency):

- Передача лишь ключевых фреймов и сжатых данных по WebSocket (с TCP_NODELAY) сводит к минимуму объём трафика.
- Генерация готового AR-кадра одной итерацией сервиса устраняет лишние раунд-трипы и делает задержку предсказуемой.
- Гибридный режим и отказоустойчивость:
 - При обрыве сети клиент автоматически переключается на облегчённые модели, обеспечивая минимальный набор функций офлайн.
 - Менеджер сети непрерывно контролирует соединение и восстанавливает полноценный серверный режим при возвращении сети.
- Масштабируемость и сопровождение:
 - Микросервисная архитектура (отдельные контейнеры под ASR, NMT, OCR, AR-рендеринг) позволяет горизонтально масштабировать узкие места под нагрузкой.
 - Централизованное обновление моделей через артефакт-репозиторий исключает перекомпиляцию клиентского приложения при выпуске новых версий ML-моделей.
- Интуитивный AR-интерфейс:
 - Серверный ARRenderer рассчитывает позиционирование, шрифт и цвет текста, а клиентская OverlayView всего лишь отображает готовую текстуру в сцене дополненной реальности.

Рассмотрим аналогичные решения и отметим свойственные им преимущества и недостатки таблице 1.

Таблица 1 – Сторонние решения

Приложение	Достоинства	Недостатки
Google Translate	перевод текста, голосовой режим, распознавание изображений, офлайн-пакеты	Имеется задержка при работе от сети

Microsoft Translator	групповые чаты, интеграция с Office, офлайн-режим	Имеется задержка при работе от сети, ограниченная точность, зависимость от сети
iTranslate	простота UI, голосовой и текстовый режимы, офлайн-пакеты	Имеется задержка при работе от сети, ограниченная точность ASR, нет пространственного вывода текста
SayHi Translate	хорошая точность распознавания речи и перевода	Имеется задержка при работе от сети отсутствует AR, зависимость от сети
Яндекс Переводчик	поддержка офлайн-режима, озвучивание перевода	Имеется задержка при работе от сети

Преимущества разрабатываемого решения:

- Полный AR-конвейер:

- Встроенная AR-визуализация переведённого текста прямо в поле зрения пользователя (через ARCore), без отвлечения на экран или аудио.

- Гибридная обработка:

- Мобильный клиент автономно выполняет базовый ASR и OCR через компактные ONNX-модели, сохраняя базовую функциональность офлайн.

- При доступе в сеть задействуется мощный серверный конвейер для повышения качества и скорости.

- Низкая и предсказуемая задержка:

- Передача только ключевых фреймов и единая итерация серверного ASR→NMT→AR минимизируют сетевые раунд-трипы.

- Масштабируемость и обновляемость:

- Микросервисы легко масштабируются под нагрузку, а централизованное хранение ONNX-моделей даёт оперативное обновление алгоритмов без релизов мобильного приложения.

- Конфиденциальность:

- Чувствительные данные (аудио, изображения) могут обрабатываться локально при отсутствии сети или при строгих требованиях безопасности, а на сервер отправляются только сжатые и необходимое для перевода данные.

- Универсальность:

- Помимо AR-перевода речи, приложение поддерживает перевод текста на изображения (OCR+AR) и текстовый ввод, объединяя весь спектр мультимодального перевода в одном интерфейсе.

Эти преимущества делают данное решение технически обоснованным и более эффективным по сравнению с существующими приложениями, особенно в сценариях, требующих низкой задержки, офлайн-работы и интуитивного AR-интерфейса.

1.5 Анализ готового программного обеспечения в области машинного перевода и их преимущества и недостатки

В процессе изучения литературы в данной области было выявлено, что для оценки программ-переводчиков применяются методы, условно разделяющиеся на четыре категории:

- Оценка качества перевода:

- BLEU (Bilingual Evaluation Understudy) — измеряет схожесть машинного перевода с эталонными переводами, сравнивая последовательности слов.

– TER (Translation Edit Rate) — показывает число правок (вставок, удалений, замен), необходимых для приведения машинного перевода к эталонному.

– ROUGE (Recall-Oriented Understudy for Gisting Evaluation) — часто используется для оценивания смыслового соответствия текстов и переводов.

– Human Evaluation (ручная оценка) — профессиональные переводчики или пользователи оценивают перевод по критериям точность, естественность и адекватность.

– Оценка распознавания речи:

– WER (Word Error Rate) — процент ошибок (вставок, удалений, замен) в распознанном тексте.

– CER (Character Error Rate) — аналогично WER, но для отдельных символов.

– Perplexity (PP) — показывает, насколько модель уверена в своих предсказаниях.

– Оценка AR-интерфейса:

– UX-тестирование (User Experience Testing) — оценивает удобство использования, читаемость текста и восприятие наложенного перевода.

– FPS (frames per second) — измеряет плавность работы AR-интерфейса.

– Latency Test — оценивает задержку от момента распознавания текста до его отображения в AR.

– Углы обзора и точность наложения — проверяет, правильно ли AR-движок располагает перевод в пространстве.

– Производительность и стабильность:

– Load Testing — проверяет работу приложения под высокой нагрузкой.

– Latency Measurement — измеряет задержки при обработке и наложении перевода.

– Кроссплатформенное тестирование — проверяет совместимость с разными устройствами и ОС.

В данной работе будут исследованы системы синхронного перевода крупнейших компаний: Google Translate, Microsoft Translator, DeepL и «Яндекс.Переводчик».

Для сравнения качества перевода используются открытые данные конференций WMT и ACL, а также тестовые отчёты изображенные в таблице 2.

Таблица 2 – Оценка качества перевода программ-переводчиков

Метрика / Система	Google Переводчик	Microsoft Translator	DeepL	Яндекс Переводчик
BLEU (англ → рус)	0.498 ± 0.226	Нет данных	0.490 ± 0.183	Нет данных
оценка machine translation	7.90	7.77	8.38	Нет данных
METEOR	42.3	41.5	46.1	39.8
TER (↓ лучше)	45 %	47 %	38 %	50 %
ROUGE-L	63 %	61 %	67 %	58 %
Human Evaluation (1–5)	4.0	3.9	4.3	3.7

Далее обратимся к исследованию, где сравнивается DeepL и Яндекс переводчик (рисунок 1).




Рисунок 1 – Сравнение DeepL и Yandex переводчик

На рисунке 1 можем наблюдать позиции, а которых лидирует как отечественный сервис, так и немецкий проект DeepL.

Вывод: при разработке приложения необходимо добиться наиболее высокого показателя приближенного к точности перевода программы DeepL. И добавить возможность работы офлайн, как это реализовать будет рассмотрено далее.

– Оценка распознавания речи. В данном разделе будут подробно приведены такие, методики оценки, как CER и WER, которые описаны в формуле (1).

Формула расчёта:

$$WER = (S+D+I)/N = (S+D+I)/(S+D+C) \quad (1)$$

где: S — количество замен;

D — количество удалений;

I — количество вставок;

C — количество корректных слов;

N — количество слов в исходной строке.

Формула для CER точно такая же, но вместо слов используются символы. При этом, при подсчёте CER мы НЕ считаем пробелы. Для каждого тестового датасета в итоге принято считать 4 величины:

- Average CER, sum of relationships — средняя частота ошибок в символах, сумма отношений.
- Average WER, sum of relationships — средняя частота ошибок в словах, сумма отношений.
- Average CER, relationship of sums — средняя частота ошибок в символах, отношение сумм.
- Average WER, relationship of sums — средняя частота ошибок в словах, отношение сумм (сортировка и присвоение мест вендоров в табличках ниже в статье производилась именно по этому параметру).

В таблице 3 были проведены измерения с использованием датасета mozilla common voice. Измерения проводились с аудиозаписями на русском языке длительностью 5 - 10 секунд, а также без шума.

Таблица 3 – Результаты измерений с использованием датасета mozilla common voice

Метрика / Система	WER (рус.)	CER (рус.)
Google Переводчик	8.5 %	2.8 %
Microsoft Translator	9.2 %	3.1 %
DeepL	10.5 %	3.5 %
Яндекс Переводчик	7.9 %	2.5 %

– Оценка работы AR-интерфейса. Для анализа AR-компонентов использовались публичные тесты, документация платформ (ARCore) и пользовательские исследования в таблице 4.

Рассмотрим ключевые метрики:

- FPS: Плавность визуализации текста в AR.
- Задержка: Время от получения перевода до его отображения.

– UX-оценка: Удобство интерфейса по шкале SUS (System Usability Scale).

Таблица 4 – Оценка работы AR-интерфейса программ переводчиков

Метрика / Сервис	Google Переводчик (AR)	Microsoft Translator AR
FPS (среднее)	25	22
Задержка (мс)	300	350
UX-оценка (SUS/100)	74	68

– Производительность и стабильность. Для оценки производительности и стабильности системы синхронного перевода использовались следующие методики изображенные в таблице 5:

– Тестирование нагрузки (Load Testing) — проверка работы приложения под высоким трафиком.

– Замер времени обработки (Latency Measurement) — анализ задержек на каждом этапе (аудио → текст → перевод → AR).

Таблица 5 – Оценка производительности и стабильности программ для перевода

Метрика / Сервис	Google Переводчик	Microsoft Translator	DeepL	Яндекс Переводчик	Источник данных
Нагрузка (RPS)	5000 (облако)	4500 (облако)	3000 (облако)	3500 (облако)	https://cloud.google.com/ , https://azure.microsoft.com/
Задержка обработки (с)	1.5	1.6	1.8	1.7	Авторские тесты
Офлайн-режим	Ограничено	Ограничено	Нет	Ограничено	—

Выявленные проблемы: Отсутствие работы в режиме офлайн или ограниченная поддержка данного формата, существенная задержка.

В процессе разработки собственного решения, необходимо осуществить высокие показатели качества перевода, разработать модуль распознавания речи и добиться высоких показателей качества и скорости распознавания, а также интегрировать возможности дополненной реальности, продумать и добавить поддержку работы в автономном режиме.

1.6 Особенности интеграции AR-технологий и машинного обучения

Интеграция технологий дополненной реальности (AR) и машинного обучения (ML) представляет собой ключевой элемент разработки приложений синхронного перевода речи. Эта комбинация позволяет создавать интеллектуальные системы, которые не только предоставляют визуальные подсказки в реальном времени, но и адаптируются к особенностям речи и поведения пользователя, улучшая общую точность и удобство использования.

Основные особенности интеграции AR и ML в приложениях синхронного перевода речи:

- Распознавание и трекинг голосовых и визуальных данных. Алгоритмы машинного обучения обеспечивают высокую точность распознавания речи, что критически важно для перевода в реальном времени. Использование AR позволяет наложить перевод в виде текстовых подсказок или анимации поверх реальной среды, облегчая восприятие информации.

- Адаптивное взаимодействие с пользователем. ML-модели анализируют акценты, скорость речи и предпочтения пользователей, чтобы адаптировать перевод и способ его отображения. Например, AR-интерфейс может предлагать различные визуальные стили текста перевода для более комфортного чтения.

- Сложные сценарии взаимодействия. Интеграция ML позволяет системе учитывать контекстные особенности речи, такие как идиомы или сложные технические термины. AR, в свою очередь, может визуализировать такие понятия с помощью графических элементов, упрощая восприятие информации.

– Реализация обработки больших объемов данных в реальном времени. Для синхронного перевода важна быстрая обработка входящей речи. ML-модели обрабатывают голосовые данные, распознают смысловые блоки и переводят их на целевой язык, тогда как AR отображает перевод без значительных задержек.

Примеры интеграции AR и ML в приложениях синхронного перевода:

– Международные конференции и переговоры. AR-приложения, оснащенные ML, могут отображать перевод речи выступающих в виде текста или субтитров, наложенных на реальную сцену. Это снижает необходимость в физическом присутствии переводчиков и минимизирует языковые барьеры.

– Образовательные программы. В учебных средах приложения синхронного перевода с использованием AR и ML помогают участникам, говорящим на разных языках, понимать лекции в режиме реального времени. Дополненная реальность может также отображать визуальные пояснения к переведенным терминам.

– Службы поддержки и обслуживания клиентов. AR-приложения с интеграцией ML могут помогать операторам поддерживать общение с клиентами, говорящими на различных языках, предоставляя перевод речи в реальном времени и накладывая его в интерфейс рабочего приложения.

Эти особенности интеграции AR и ML в контексте синхронного перевода речи предоставляют широкие возможности для создания удобных и высокоэффективных систем. В следующих главах мы подробно рассмотрим алгоритмы, подходы и инструменты, используемые для реализации такого рода приложений.

1.7 Ограничения и требования для мобильных приложений

Разработка мобильных приложений, сочетающих дополненную реальность (AR) и машинное обучение (ML), сопровождается рядом ограничений и требований, которые следует учитывать на этапе проектирования. Для успешной реализации таких приложений, как система синхронного перевода речи, важно сбалансировать функциональные возможности с техническими ограничениями мобильных устройств.

Основные ограничения мобильных приложений:

– Ограниченная производительность аппаратного обеспечения. Мобильные устройства обладают ограниченными вычислительными ресурсами. Это сказывается на скорости обработки данных, особенно в задачах машинного обучения и отображения сложной AR-графики в реальном времени. Например, использование ML-моделей для обработки речи и генерации перевода требует оптимизации алгоритмов, чтобы минимизировать нагрузку на процессор и графический чип.

– Потребление энергии. Постоянная работа микрофона, камеры и вычислительных модулей для AR и ML быстро разряжает аккумулятор устройства. Это требует оптимизации приложений для снижения энергопотребления, например, через использование специализированных библиотек, таких как TensorFlow Lite или Core ML.

– Ограничения памяти и хранения данных. Большие модели машинного обучения и AR-ресурсы могут занимать значительный объем памяти. Это требует использования сжатых моделей или облачных вычислений для хранения и обработки данных.

– Скорость соединения и задержки передачи данных. Если приложение зависит от облачных серверов для обработки речи и перевода, то качество работы напрямую зависит от скорости интернет-соединения. Задержки в передаче данных могут негативно сказаться на синхронности перевода.

Основные требования к мобильным приложениям:

– Юзабилити и интуитивный интерфейс. Пользовательский интерфейс должен быть простым и удобным, чтобы отображать переводы ненавязчиво, но понятно. Например, перевод может накладываться на поле зрения пользователя в виде текста или иконок с минимальным отвлечением внимания.

– Минимальные задержки при переводе. Для задач синхронного перевода критически важно обеспечить низкую задержку между распознаванием речи, обработкой и отображением перевода. Это может быть достигнуто за счет оптимизации процессов обработки и выбора подходящих ML-моделей.

- Поддержка различных условий использования. Приложение должно корректно работать в условиях слабого освещения, шумного окружения или нестабильного интернет-соединения.

Примеры подходов к оптимизации:

- Использование предварительно обученных компактных ML-моделей для локальной обработки.

- Адаптация AR-функциональности под ограничения мобильных устройств через упрощение графических эффектов.

- Разделение нагрузки между устройством и облачным сервером (гибридная обработка данных).

В рамках будущей разработки приложения синхронного перевода речи важно учитывать эти ограничения и требования для создания устойчивого, функционального и удобного продукта. Более глубокий анализ технических решений и их оптимизации будет представлен в следующих главах.

1.8 Определение основных направлений разработки

На основании анализа существующих технологий, приложений и подходов в области синхронного перевода речи можно выделить ключевые направления, которые будут определять процесс разработки будущего приложения, интегрирующего AR-технологии и методы машинного обучения.

Рассмотрим эти ключевые направления:

- Создание точной системы распознавания и перевода речи. Для обеспечения высококачественного перевода необходимо разработать и внедрить эффективную модель распознавания речи. Это включает:

- Использование нейронных сетей, обученных моделей и библиотек для обработки звукового сигнала.

- Адаптацию модели к разным акцентам, языковым диалектам и шумовым условиям.

- Интеграцию алгоритмов машинного обучения для обучения системы на пользовательских данных с целью повышения ее точности.

– Интеграция дополненной реальности для отображения перевода. Применение AR позволит улучшить пользовательский опыт за счет визуализации перевода, таким образом, как размещение текста перевода в пространстве, понятном пользователю.

– Оптимизация алгоритмов для работы в реальном времени. Для синхронного перевода речи важно минимизировать задержки:

– Использование компактных и высокопроизводительных моделей.

– Обработка данных как на устройстве, так и на сервере.

– Разработка механизма кэширования данных для ускорения повторного перевода.

– Разработка адаптивного пользовательского интерфейса. Пользовательский интерфейс должен быть интуитивно понятным и адаптируемым:

– Предоставление персонализированных настроек (например, выбор языка или способа отображения перевода).

– Использование голосовых и визуальных подсказок для удобства работы с приложением.

– Обеспечение конфиденциальности данных. Сохранность пользовательских данных является важным аспектом разработки:

– Шифрование передаваемых данных.

– Использование локальной обработки данных, где это возможно.

– Модульное построение системы. Для обеспечения гибкости и масштабируемости системы необходимо реализовать модульную архитектуру:

– Отдельные модули для распознавания речи, перевода текста и работы с AR-интерфейсом.

– Возможность добавления новых языков или функций без изменения базовой структуры.

2 АЛГОРИТМИЧЕСКОЕ РЕШЕНИЕ ИССЛЕДУЕМОЙ ЗАДАЧИ И ВЫБОР ПРОГРАММНО-ТЕХНИЧЕСКОЙ ПЛАТФОРМЫ

2.1 Алгоритмическая модель приложения синхронного перевода речи с применением AR-технологий и машинного обучения

Система синхронного перевода речи реализована по классической клиент-серверной архитектуре, обеспечивающей гибкость, масштабируемость и поддержку как онлайн, так и оффлайн-режима. Компоненты взаимодействуют асинхронно, с минимальной задержкой, что критически важно для обработки речевых данных в реальном времени.

– Мобильный клиент (Android-приложение). Мобильное приложение разработано на Kotlin с использованием Android Studio и включает следующие ключевые функции:

– Захват аудиопотока с микрофона, его предварительная обработка (шумоподавление, нормализация громкости) и кодирование для передачи на сервер.

– Обработка текста и визуализация перевода в дополненной реальности (AR) с использованием CameraX и PaddleOCR.

– Взаимодействие с сервером через WebSocket-соединение для получения переведённого текста в реальном времени.

– Оффлайн-режим, при котором приложение способно выполнять ключевые функции без подключения к интернету:

– Распознавание текста на изображении с помощью PaddleOCR.

– Перевод с использованием локальных языковых моделей ML Kit Translate.

– Отображение перевода в AR без серверной поддержки.

– Кэширование переводов и пользовательских настроек через SQLite, что позволяет ускорить повторные запросы и снизить сетевую нагрузку.

– Серверная часть (FastAPI-приложение). Сервер реализован на языке Python с использованием фреймворка FastAPI, предоставляющего производительный и асинхронный REST и WebSocket API. Основные функции:

– Обработка аудиопотока, полученного от клиента, включая декодирование и нормализацию сигнала.

– Распознавание речи (ASR) с помощью модели Whisper или альтернативных решений.

– Машинный перевод (MT) с использованием MarianMT или других моделей от Hugging Face Transformers.

– Синтез речи (TTS) — по запросу клиента текст может быть преобразован в аудиофайл на целевом языке.

– Стриминг переведённого текста или аудио клиенту в режиме реального времени по WebSocket.

– Интеграция с базой данных для хранения пользовательских данных, логов взаимодействия и сессий перевода.

– Механизм взаимодействия между клиентом и сервером. Коммуникация между мобильным клиентом и сервером осуществляется двумя способами:

– REST API:

– инициализация и настройка пользовательской сессии;

– запрос доступных языков и моделей;

– получение параметров и конфигураций системы.

– WebSocket:

– потоковая передача аудиофреймов от клиента к серверу;

– получение от сервера переведённых текстов или аудиофрагментов в реальном времени;

– обеспечение минимальной задержки в канале передачи данных.

На рисунке 2 представлена визуальная схема архитектуры приложения, отражающая структуру компонентов и направления взаимодействия между ними.

Схема отражает как серверную, так и клиентскую структуру, а также варианты автономной работы клиента без подключения к сети.




Рисунок 2 – Схема архитектуры приложения

Диаграмма прецедентов отображает основные функции системы с точки зрения конечного пользователя. В контексте разрабатываемого приложения для синхронного перевода речи и текста с элементами дополненной реальности (AR), функциональность распределяется между мобильным клиентом (Android) и серверной частью (Python + ML).

Система позволяет пользователю выполнять как локальные (автономные) операции, так и обращаться к внешнему серверу для ресурсоёмкой обработки (OCR, AR-визуализация).

- Основные прецеденты взаимодействия представлены на рисунке 3:
- Запуск режима перевода. Пользователь запускает приложение и активирует один из режимов: перевод речи, текста или OCR.
- Выбор типа входных данных. Пользователь выбирает, что он хочет перевести: устную речь, введённый текст или текст с изображения (OCR).

- Выбор языков перевода. В настройках задаются исходный и целевой языки. Эти параметры используются как для распознавания речи, так и для текстового ввода и OCR.

- Локальная (автономная) обработка на клиенте:

- Захват и распознавание речи. Клиент записывает речь пользователя, выполняет локальное распознавание с помощью встроенной модели или внешней библиотеки (в зависимости от режима и мощности устройства).

- Ввод и перевод текста вручную. Пользователь вводит текст с клавиатуры. Машинный перевод текста осуществляется на устройстве локально с использованием предзагруженной модели (например, MarianMT с помощью ONNX).

- Отображение перевода текста/речи в AR. В случае автономной работы система может отобразить результат перевода используя предзагруженные библиотеки.

- Серверная обработка (OCR и AR с визуализацией):

- Захват изображения с камеры. Пользователь делает снимок сцены, содержащей текст (например, надпись, документ, вывеска).

- Отправка изображения на сервер. Клиент передаёт изображение через WebSocket на сервер для дальнейшей обработки.

- Распознавание текста с изображения (OCR). Сервер выполняет OCR с использованием PaddleOCR, извлекая текстовые блоки и их координаты.

- Формирование изображения с AR-наложением. Переведённый текст вставляется обратно в изображение с сохранением исходных координат и визуального соответствия (позиция, размер, цвет).

Таким образом, система реализует гибкий подход: простые и быстрые действия (распознавание речи и перевод текста) выполняются автономно на клиенте, в то время как ресурсоёмкие задачи (OCR и визуальная интеграция в AR-

сцену) обрабатываются на сервере. Эта модель позволяет достичь баланса между скоростью, точностью и приватностью.




Рисунок 3 – Диаграмма прецедентов приложения синхронного перевода

Каждый прецедент отображает отдельную часть функциональности, необходимую для выполнения задачи перевода. Взаимодействие между актором (пользователем) и системой иллюстрирует, как шаг за шагом происходит процесс работы системы синхронного перевода.

Далее, чтобы отразить взаимодействие между объектами или компонентами системы во времени перейдем к диаграмме последовательности. Диаграмма последовательности иллюстрирует взаимодействие между основными компонентами системы во времени при выполнении конкретного сценария — синхронного перевода речи с отображением результата через дополненную реальность. Она позволяет наглядно проследить, как инициируется, обрабатывается и визуализируется перевод, а также какие модули задействованы на каждом этапе.

Участники диаграммы:

– Пользователь — инициирует запуск перевода речи.

- Клиент (мобильное приложение) — захватывает речь, управляет соединением с сервером и отображает результат.
- Сервер — принимает аудиоданные, управляет потоком обработки.
- ASR-модуль — выполняет распознавание речи.
- MT-модуль — осуществляет машинный перевод текста (MarianMT).
- AR-компонент клиента — отвечает за визуализацию переведённого текста в дополненной реальности.
- Сценарий: «Синхронный перевод речи».
- Пользователь нажимает кнопку «Начать перевод».
- Клиент активирует микрофон и запускает захват аудио.
- Аудиофреймы обрабатываются (нормализация, шумоподавление) и передаются на сервер через WebSocket.
- Сервер принимает поток и передаёт его в ASR-модуль.
- ASR-модуль выполняет распознавание речи и возвращает текст на сервер.
- Сервер передаёт полученный текст в MT-модуль.
- MT-модуль возвращает переведённый текст.
- Сервер отправляет переведённый текст обратно на клиент.
- Клиент передаёт текст в AR-компонент.
- AR-компонент визуализирует переведённую фразу в пространстве на экране. Представим графическую диаграмму последовательностей на рисунке 4.




Рисунок 4 – Диаграмма последовательностей приложения синхронного перевода

Добавим пояснения:

- Асинхронность передачи: Передача данных между клиентом и сервером может быть асинхронной, чтобы не блокировать интерфейс пользователя.
- Логическая связность: Последовательность операций организована так, чтобы пользователь получал результат максимально быстро, а система могла при этом работать стабильно даже при непредсказуемых сетевых задержках.
- Возможность повторной обработки: при потере связи или ошибке распознавания пользователь может инициировать повторную отправку аудио.

Диаграмма состояний отражает ключевые этапы жизненного цикла компонентов системы и их переходы из одного состояния в другое. Это наглядный инструмент для понимания последовательности событий, логики обработки данных и реакции системы на действия пользователя.

Для системы синхронного перевода речи с визуализацией перевода в дополненной реальности можно выделить два основных блока состояний — на стороне клиентского мобильного приложения и серверной части.

- Состояния клиента (мобильного приложения):
 - Ожидание. Начальное состояние системы. Приложение готово к работе. Пользователь может выбрать язык, подключить сервер и настроить параметры отображения.

- Загрузка словарей и моделей. При первом запуске или при смене языка приложение загружает необходимые локальные данные (например, модели перевода или метаданные).
- Обработка настроек. Применяются пользовательские параметры: выбор языковой пары, режим отображения текста, параметры AR.
- Захват речи. Активируется микрофон. Производится захват, фильтрация и буферизация аудиосигнала.
- Обработка аудио. Аудиоданные преобразуются в текст (распознавание речи). Это может выполняться локально или отправляться на сервер.
- Отправка изображения на сервер. В случае работы с OCR, клиент делает снимок и передаёт его серверу для распознавания текста и генерации AR-изображения.
- Отображение в AR. Переведённый текст выводится на экран пользователя с использованием технологий дополненной реальности. Возможно, как локальное, так и серверное наложение текста.
- Завершение сессии. Пользователь вручную завершает текущий цикл перевода. Приложение очищает состояние и переходит в режим ожидания.
- Состояния сервера:
 - Ожидание запроса. Сервер находится в режиме готовности, ожидая входящие соединения от клиентов.
 - Получение изображения. После установления соединения сервер принимает изображение от клиента, содержащее текст.
 - Обработка текста на изображении. Сервер выполняет:
 - Распознавание текста с изображения (OCR через PaddleOCR).
 - Машинный перевод распознанного текста (через MarianMT).
 - Формирование нового изображения с наложенным переводом (AR-аннотация).

– Передача AR-изображения клиенту. Готовое изображение с визуализированным переводом отправляется клиенту по WebSocket. После успешной отправки сервер возвращается в состояние ожидания.

На диаграмме состояний (рисунок 5) эти процессы представлены в виде блоков с переходами, где каждый переход инициируется действием пользователя или завершением этапа обработки. Такая диаграмма помогает формализовать поведение системы и упростить отладку и масштабирование на следующих этапах разработки.




Рисунок 5 – Диаграмма состояний

Таким образом было составлено наглядное представление алгоритма действий пользователя при взаимодействии с программой.

2.2 Профильное программное обеспечение для реализации клиента и сервера

В этом разделе описывается полный стек программных компонентов, необходимых для серверной и клиентской частей системы. Ключевая цель — обеспечить эффективное взаимодействие модулей, минимизировать задержки и оптимизировать загрузку устройств.

2.2.1 Серверная часть

– Язык и фреймворк: Python + FastAPI. FastAPI выбран благодаря поддержке асинхронных маршрутов и WebSocket, простоте описания схем данных

(Pydantic) и автоматической генерации OpenAPI-документации. Его производительность близка к Go-решениям за счёт использования Starlette и Uvicorn.

- ASGI-сервер: Uvicorn. Используется для запуска FastAPI-приложения в асинхронном режиме. Поддержка HTTP/2 и WebSocket, возможность автоматической перезагрузки при разработке.

- ML-движок: ONNX Runtime / TensorFlow:

- ONNX Runtime обеспечивает единый интерфейс для запуска нейросетевых моделей (Whisper, MarianMT, PaddleOCR) на GPU и CPU.

- TensorFlow / TensorFlow Lite используется для прототипирования и тестирования, а также для работы с собственными моделями.

- Модуль машинного перевода (MT). MarianMT (Hugging Face) обеспечивает перевод с учётом контекста. Модель развёрнута в ONNX-формате для быстрого вывода.

- Модуль OCR. PaddleOCR объединяет три этапа: detection (обнаружение текстовых блоков), classification (ориентация) и recognition (извлечение символов). Поддерживает 80+ языков.

- Кэш и очереди: Redis. In-memory кэш ускоряет повторные запросы. Pub/Sub и списки Redis используются для управления очередями задач между микросервисами (ASR → MT → OCR → AR).

- Оркестрация и контейнеризация. Docker для упаковки каждого микросервиса.

2.2.2 Клиентская часть (Android)

Ниже приведён подробный профиль компонентов Android-клиента с обоснованием выбора каждого инструмента.

- Язык и среда разработки: Kotlin + Android Studio. Kotlin обеспечивает лаконичный синтаксис и полную совместимость с Java-экосистемой. Android Studio предоставляет встроенные инструменты отладки, профилирования и генерации APK, а также поддержку Gradle для гибкой конфигурации сборки.

- UI-слой: Jetpack Compose (Material Design 3):

- Декларативный подход упрощает создание динамических интерфейсов через функции-компоненты, снижая boilerplate-код.
- Material 3 даёт доступ к новым визуальным элементам и темам («Dynamic Color»), автоматически адаптирующимся под фон устройства.
- Камера и AR: CameraX + ARCore / Sceneform:
 - CameraX абстрагирует разные уровни API камеры, упрощая захват кадров и управление жизненным циклом.
 - ARCore (в связке с Sceneform) обеспечивает трекинг плоскостей, определение позы устройства и удобный рендер 3D-объектов, в том числе текста перевода, прямо в пространстве пользователя.
- Локальный ML-движок. Предобученные модели для простого перевода, работают без сервера, но с ограниченным набором языков:
 - ONNX Runtime for Android. Запуск кастомных нейросетевых моделей (Whisper-Tiny, PP-OCRv3-Lite, локальные переводчики) напрямую в APK, использует NNAPI/NPU при наличии.
 - OpenCV. Предобработка изображения (фильтрация, бинаризация, выравнивание) перед OCR, повышая точность распознавания.
 - VoskОфлайн-ASR без Gradle-зависимостей (native .aar), малозатратный по ресурсам, поддерживает десятки языков.
- Сетевое взаимодействие: Retrofit + OkHttp:
 - Retrofit генерирует API-клиент по интерфейсам, упрощает парсинг JSON (Gson/ Moshi).
 - OkHttp отвечает за устойчивые HTTP, WebSocket-соединения с опциями сетевого кэширования, логирования и таймаутов.
- Локальное хранение: SQLite + DataStore.
 - SQLite (через Room) хранит историю переводов, пользовательские настройки и кэш ответов сервера.
 - DataStore (Jetpack) применяется для лёгких конфигураций (языков, параметров AR), гарантируя атомарность и безопасность.

- Multidex. Позволяет помещать более 65 536 методов в один APK, что актуально при множестве ML и AR-библиотек.

- Тестирование:

- JUnit4 и `androidx.test.ext:junit` для юнит-тестов логики.

- Espresso и `ui.test.manifest` для UI-тестов Compose и CameraX/AR-экранов.

- MockWebServer эмулирует сервер для тестирования Retrofit/WebSocket.

Ключевые требования к клиенту:

- Производительность: все пользовательские действия (запуск записи, визуализация AR) должны происходить без просадок FPS и заметных лагов.

- Поддержка Android 12.0 + с учётом разных CPU/GPU/NPU конфигураций.

- Автономность: базовый ASR и перевод работают без интернета.

- Масштабируемость: добавление новых языков и моделей через обновление артефактов на сервере и загрузку ONNX-пакетов.

2.3 Синтез алгоритма обработки речевых данных

Разработанная система синхронного перевода речи реализует полный конвейер обработки аудиопотока, оптимизированный под требования реального времени и интегрируемый в мобильные и AR-приложения. Все этапы связаны через асинхронные каналы и coroutine-архитектуру Kotlin, обеспечивая параллелизм и устойчивость.

Этапы обработки:

- Захват и буферизация аудио:

- Активация микрофона и непрерывный захват аудиопотока в формате 16 кГц, 16 бит, моно.

- Кольцевой буфер (ring buffer) реализован на клиенте с учётом минимальных задержек и безопасной записи в многопоточном режиме.

- Предобработка аудио:

- Удаление шума и эха, нормализация уровня громкости.

- Автоматическое определение пауз и их удаление для снижения трафика.
- Аудиокодирование:
 - Использование Opus-кодека для сжатия аудиофреймов и снижения нагрузки на сеть.
 - Поддержка кодирования в реальном времени с возможностью восстановления качества на стороне сервера.
- Передача и приём аудио:
 - Поточковая передача по WebSocket с минимальной буферизацией.
 - На сервере: декодирование и восстановление последовательности аудиофреймов.
- Распознавание речи (сервер):
 - Передача на ASR-сервис (таких как, Whisper или Vosk).
 - Реализовать возможность офлайн-распознавания с помощью аппаратных возможностей.
- Распознавание речи (клиент). Использование TTS-библиотек.
- Нормализация текста:
 - Очистка ASR-выхода от шумов, артефактов, автокоррекция регистра и пунктуации.
 - Приведение текста к единому формату для дальнейшей обработки.
- Машинный перевод (MT):
 - Использование предварительно загруженной модели машинного перевода.
 - Поддержка нескольких языковых направлений, адаптация под диалекты.
- Форматирование для AR-интерфейса:
 - Отображение переведённого текста.
 - Нормализация перспективы (предполагается работа с искажениями текста).

- Использование библиотек компьютерного зрения, основанных на машинном обучении, таких как PaddleOCR.
- Генерация готовых для рендеринга слоёв текста для AR-отображения.
- Синтез речи:
 - Генерация голосового перевода с помощью TTS-моделей.
 - Интеграция с аппаратными компонентами на клиентской стороне.
- Возврат и визуализация:
 - Передача текста или аудиофайлов клиенту через WebSocket.
 - Отображение текста в реальном времени поверх видеопотока камеры с использованием CameraX и PaddleOCR.

Архитектура и принципы проектирования:

- Чистая архитектура (Clean Architecture): чёткое разделение на слои: presentation, domain, data, с применением интерфейсов и инверсии зависимостей.
- Микросервисная организация: ключевые компоненты (ASR, MT, TTS) оформлены как отдельные Docker-сервисы, масштабируемые независимо.
- 12-факторный подход: все параметры конфигурации (язык, кодек, режимы) управляются через переменные окружения и внешние конфигурации.
- Распределённая нагрузка: клиент обрабатывает захват, визуализацию и кодирование, сервер — ресурсоёмкие этапы: распознавание, перевод и синтез речи.
- Коррутины и Flow: эффективное использование асинхронных потоков в Kotlin для обработки и маршрутизации аудиоданных без блокировки UI.

2.4 Интеграция технологий машинного обучения и дополненной реальности

Далее в разработанная системе рассмотрим объединение возможностей компьютерного зрения и дополненной реальности (AR), чтобы извлекать и визуализировать текст с камеры устройства. Архитектура построена по клиент-серверной модели с чётким разделением обязанностей: клиент отвечает за захват и отображение, сервер — за интеллектуальную обработку изображений.

– Машинное обучение в серверной обработке изображений. Клиент (Android-приложение, реализованное на Kotlin с использованием coroutines и AR) передаёт на сервер последовательность изображений с камеры. Далее на сервере происходит следующий процесс:

– OCR (распознавание текста). Используется библиотека PaddleOCR, которая извлекает текст из изображения, включая поддержку многоязычного контента и рукописного ввода. Модель корректно работает с разными ориентациями, стилями шрифта и фоновыми шумами.

– Перевод текста (MT). Извлечённый текст автоматически передаётся в модель MarianMT сервера для перевода на целевой язык. Обеспечивается сохранение контекста и точность лексического соответствия.

– Визуальное наложение (AR-аннотация). Переведённый текст программно встраивается в исходное изображение. Текст адаптируется под исходные координаты, стиль и ориентацию, создавая эффект "естественного" встраивания с сохранением AR-контекста.

– Формирование результата. Готовое изображение с наложенными AR-текстами возвращается клиенту в виде файла в формате JPEG/PNG, готового к отображению.

– Визуализация в дополненной реальности на клиенте. На стороне клиента используется ARCore для создания интерактивной AR-сцены. Полученные с сервера изображения выводятся в режиме наложения:

– AR-слой отображает переведённый текст как часть окружающего пространства, точно вписанную в исходное изображение.

– Поддерживается отслеживание движения и корректировка положения изображения в пространстве.

– Клиент-серверная архитектура взаимодействия. На примере клиента (Android / Kotlin):

– Захватывает изображения с камеры.

– Отправляет кадры на сервер по WebSocket.

- Получает обработанные изображения с наложенным переведённым текстом.
- Отображает результат в AR-сцене с возможностью интерактивного управления.
- Сервер (Python / FastAPI):
 - Получает изображения, выполняет OCR → MT → наложение текста.
 - Возвращает результат обратно клиенту в виде обработанных изображений.

Такой подход обеспечивает высокую точность извлечения текста и гибкость его визуализации, создавая эффект дополненной реальности, при этом минимизируя нагрузку на клиентское устройство. Благодаря распределённой архитектуре и использованию проверенных ML-инструментов система легко масштабируется и адаптируется под разные языковые и визуальные сценарии.

2.5 Системные требования

Система синхронного перевода речи с использованием технологий дополненной реальности и методов машинного обучения предъявляет определённые требования как к клиентскому устройству (мобильному приложению), так и к серверной части, выполняющей основные вычисления. Ниже представлены минимальные и рекомендуемые системные конфигурации.

- Клиентская часть (мобильное приложение). Минимальные требования:
 - операционная система: Android 12.0 и выше;
 - процессор: 4-ядерный ARM (частота от 1.8 ГГц);
 - оперативная память: не менее 6 ГБ;
 - камера: поддержка ARCore;
 - свободное место в хранилище: от 400 МБ;
 - интернет-соединение: стабильный канал от 10 Мбит/с;
 - дополнительно: поддержка OpenGL ES 3.0.
- Рекомендуемые требования:
 - операционная система: Android 11 и выше;

- процессор: 8-ядерный ARM с поддержкой нейросетевых вычислений (NPU);
- оперативная память: от 8 ГБ;
- камера: поддержка расширенного набора AR-функций (ARCore Depth API, Motion Tracking);
- интернет-соединение: от 15 Мбит/с и выше.
- Серверная часть (backend-приложение). Минимальные требования:
 - операционная система: Ubuntu 20.04 LTS или Windows Server 2019;
 - процессор: Intel Core i5 / AMD Ryzen 5 (4 ядра);
 - оперативная память: 8 ГБ;
 - хранилище: от 10 ГБ свободного места;
 - сетевое подключение: пропускная способность от 10 Мбит/с.
- Рекомендуемые требования:
 - операционная система: Ubuntu 22.04 LTS или Windows Server 2019;
 - процессор: Intel Core i7 / AMD Ryzen 7 и выше;
 - оперативная память: от 16 ГБ;
 - графический ускоритель (GPU): NVIDIA с поддержкой CUDA (для ускорения работы моделей на ONNX / PyTorch);
 - хранилище: 50 ГБ и более;
 - интернет-соединение: от 20 Мбит/с.
- Программные зависимости и библиотеки:
 - среда выполнения: Python 3.12+;
 - машинное обучение: torch, transformers, whisper, onnxruntime;
 - API: fastapi, uvicorn;
 - аудиообработка: pydub, ffmpeg;
 - сериализация и обмен: json, requests;
 - работа с данными: numpy, scipy;
 - AR и мобильные компоненты: ARCore (Android), CameraX, OpenCV, ML Kit, PaddleOCR (клиент/сервер);
 - форматы данных: wav, mp3, png, jpeg, JSON (UTF-8).

2.6 Реализация клиент-серверного взаимодействия

В основе обмена данными между Android-клиентом и сервером лежит комбинированная схема с использованием REST API для настройки и WebSocket для передачи мультимедийных фреймов. Клиент периодически отправляет на сервер изображения (JPEG/PNG) с наложенными метаданными: исходным и целевым языком перевода. Сервер обрабатывает каждый кадр через цепочку микросервисов (OCR → MT → AR-рендеринг) и возвращает клиенту готовый AR-кадр.

Все серверные компоненты упакованы в Docker-контейнеры и взаимодействуют друг с другом внутри виртуальной сети:

- Сервис подключения (FastAPI + Uvicorn):

- Принимает HTTP-запрос на инициализацию сессии: пользователь передаёт параметры `source_lang` и `target_lang`.

- Открывает WebSocket-канал `/ws/translate`, по которому далее пойдут изображения.

- OCR-сервис (PaddleOCR):

- Получает через внутренний gRPC/HTTP вызов кадр в бинарном формате.

- Выполняет `detection`, `classification` и `recognition`, возвращает распознанный текст (T).

- MT-сервис (MarianMT-ONNX):

- Принимает распознанный текст (T) и параметры языков из сервиса подключения.

- Возвращает переведённую строку (T').

- AR-рендеринг-сервис:

- Комбинирует оригинальное изображение и (T') в финальный AR-кадр, рассчитывая позицию, шрифт и цвет.

- Возвращает готовый PNG на Connection Service.

- Redis используется как меж-сервисный кэш распознанного текста и очереди задач, чтобы ускорить повторные запросы и балансировать нагрузку.

- WebSocket-передача изображений:

- Клиент кодирует кадр CameraX в JPEG/PNG, упаковывает в бинарный фрейм с HTTP-заголовком.
- Принимает на сервере (FastAPI).
- Взаимодействие микросервисов:
 - Сервис подключения из очереди Redis вызывает OCR-сервис.
 - OCR-сервис возвращает (T) и сервис подключения кладёт задачу в очередь.
 - MT-сервис забирает T и переводит.
 - Сервис подключения передаёт в AR-рендеринг-сервис вместе с оригиналом.
 - AR-рендер возвращает финальный кадр, который Connection Service шлёт обратно по WebSocket.

В итоге такое решение обеспечивает:

- гибкость развёртывания (локально или в облаке);
- низкую латентность за счёт WebSocket и микросервисного конвейера;
- централизованное управление языковыми настройками;
- отказоустойчивость и масштабируемость благодаря Redis и Docker.

2.7 Определение основных направлений разработки

Одним из наиболее существенных ограничений большинства современных решений в области машинного зрения и перевода является их жёсткая привязка к централизованным облачным платформам. Такая архитектура требует постоянного интернет-соединения, может вызывать высокую задержку и несёт потенциальные риски утечки персональных или корпоративных данных.

В данной разработке сделан акцент на гибкость, автономность и децентрализацию. Система спроектирована таким образом, чтобы пользователь мог самостоятельно определять степень локальности обработки, выбирая между работой с облачным сервером, домашним ПК или даже автономным режимом.

Основные направления и преимущества выбранного подхода:

– Локальная автономность. Ключевые функции — перевод текста и перевод речи — выполняются на стороне клиента (Android-устройства). Это позволяет использовать систему даже в условиях нестабильного или отсутствующего интернет-соединения.

– Конфигурируемое клиент-серверное взаимодействие. Пользователь вручную задаёт IP-адрес сервера, выбирая между локальной машиной и облачным хостингом. Такая архитектура подходит как для домашних сценариев, так и для развёртывания внутри корпоративных сетей.

– Минимизация задержек. Передача данных по WebSocket и локальная предварительная обработка позволяют существенно сократить время отклика, обеспечивая быстрый отклик интерфейса дополненной реальности.

– Приватность и контроль над данными. Благодаря тому, что изображения обрабатываются на контролируемом сервере, без обращения к сторонним API, обеспечивается высокий уровень конфиденциальности. Это особенно актуально для пользователей, работающих с чувствительной информацией.

– Адаптивность архитектуры. Система легко масштабируется и может быть адаптирована под разные вычислительные мощности — от мобильного устройства до облачного кластера. Контейнеризация серверной части упрощает переносимость и развёртывание в любых условиях.

Таким образом, основное направление развития проекта — создание адаптивной, устойчивой к внешним факторам архитектуры, где пользователь сам определяет баланс между производительностью, безопасностью и удобством.

3 ПРОГРАММНАЯ РЕАЛИЗАЦИЯ ПРЕДЛАГАЕМОГО АЛГОРИТМА РЕШЕНИЯ ЗАДАЧИ

3.1 Основные этапы практической разработки программного продукта

3.1.1 Модель жизненного цикла программного обеспечения

При разработке программного обеспечения для системы синхронного перевода речи с использованием технологий машинного обучения и дополненной реальности была выбрана инкрементная модель жизненного цикла.

Инкрементная модель — это метод разработки, при котором система создаётся и вводится в эксплуатацию поэтапно. Каждый этап (инкремент) представляет собой законченную часть функциональности, которая дополняет уже реализованные и протестированные модули. Новые компоненты добавляются постепенно, что позволяет получать рабочий продукт на каждом этапе разработки.

Причины выбора инкрементной модели. Выбор инкрементной модели обусловлен особенностями проекта:

- Сложность и многокомпонентность системы. Наша система включает в себя клиентскую и серверную часть, модули машинного обучения, распознавания речи и визуализации AR. Инкрементный подход позволил последовательно реализовать и тестировать каждый из компонентов, не дожидаясь завершения всей разработки.

- Гибкость в процессе разработки. Возможность вносить изменения и улучшения по мере появления новых требований или обнаружения проблем в предыдущих версиях. Например, после реализации первого инкремента — базовой передачи аудио от клиента на сервер — стало понятно, как улучшить формат данных и повысить стабильность соединения.

- Раннее получение работающего прототипа. Уже на ранних этапах проекта можно было получить минимальный рабочий вариант системы и начать тестирование, что значительно ускорило выявление и исправление ошибок.

Таким образом, использование инкрементной модели жизненного цикла позволило повысить управляемость проекта, ускорить разработку и обеспечить стабильную поэтапную реализацию всех функций системы синхронного перевода речи.

3.1.2 Состав работ по созданию системы синхронного перевода речи

Создание системы синхронного перевода речи с использованием технологий машинного обучения и дополненной реальности представляет собой сложный и многоэтапный процесс, который включает в себя как проектно-аналитическую, так и практическую разработку серверной и клиентской части программного обеспечения. В рамках выполнения проекта были выделены следующие ключевые этапы:

- Анализ предметной области и постановка задачи. На этом этапе было проведено изучение существующих решений в области синхронного перевода, их архитектур, преимуществ и недостатков. Также был определён набор требований, которые должна удовлетворять разрабатываемая система.

- Определение архитектуры и принципов взаимодействия компонентов. Была выбрана клиент-серверная архитектура, в которой:

- Сервер обрабатывает изображения с клиента, выполняет перевод и отправляет изображение с наложенным AR-переводом.

- Клиентское мобильное приложение захватывает речь пользователя, осуществляет обработку и перевод, отправляет изображение с камеры устройства на сервер, а затем отображает результат с помощью AR.

- В рамках этого этапа была также определена технология передачи данных, формат запросов и структура ответов.

- Проектирование функциональности и взаимодействия с пользователем. На этом этапе были определены основные пользовательские сценарии, составлены диаграммы прецедентов и другие, а также описано, какие действия доступны пользователю:

- инициализация и настройка сессии;

- захват и предварительная обработка данных;
- локальный офлайн-режим;
- сетевое взаимодействие;
- отправка данных на сервер;
- приём и отображение результата.

– Разработка алгоритма обработки аудиоданных. Был составлен алгоритм захвата, обработки и перевода речи с учётом особенностей работы с аудиофайлами и технологий машинного обучения. Также реализована предварительная фильтрация и нормализация входных данных.

– Разработка алгоритма перевода текста, загрузка и настройка необходимых библиотек.

– Реализация серверной части. На этом этапе была реализована серверная часть на языке Python. Основные задачи сервера:

- инициализация сессии;
- управление соединением;
- приём и буферизация изображений;
- оптическое распознавание текста (OCR);
- машинный перевод (MT);
- рендеринг AR-изображения;
- отправка результата.

Также сервер включает в себя логику логирования, обработки ошибок и ведения базовых логов.

– Разработка клиентского мобильного приложения. Мобильное приложение разрабатывается на платформе Android с использованием языка Kotlin.

– Интеграция и отладка клиент-серверного взаимодействия. После реализации обеих частей системы была проведена интеграция, обеспечивающая корректную работу при передаче и получении данных между клиентом и сервером. Особое внимание уделялось стабильности соединения и обработке различных сетевых ошибок.

– Тестирование и оценка работоспособности. Финальным этапом является тестирование:

- функциональное (работают ли все функции);
- нагрузочное (как система ведёт себя при длительной работе);
- пользовательское (насколько интерфейс удобен и понятен).

Этапы разработки по инкрементной модели. Ниже приведена таблица 6, иллюстрирующая, как была реализована система поэтапно:

Таблица 6 – Этапы разработки

Номер	Этап	Результат
1	Разработка базового клиента и сервера	Рабочее соединение между клиентом и сервером
2	Интеграция необходимых модулей, отладка, исправление ошибок и предупреждений	Успешное TDD тестирование каждого модуля
3	Подключение нейросетевого переводчика	Перевод работает, необходимые языковые словари загружаются
4	AR-визуализация перевода на клиенте	OCR успешно распознает текст и возвращает результат клиенту
5	Тестирование и оптимизация	Повышение стабильности и отзывчивости системы

Таким образом, разработка системы синхронного перевода речи охватывает полный цикл создания программного продукта — от анализа до тестирования. Каждый из этапов играл ключевую роль в обеспечении качества, стабильности и функциональности итоговой системы.

3.1.3 Функциональные требования к системе

Функциональные требования описывают, какие задачи система должна выполнять, а также как различные её компоненты (сервер и клиент) должны взаимодействовать. Для системы синхронного перевода речи с использованием машинного обучения и дополненной реальности, функциональные требования можно разделить на несколько ключевых блоков: захват речи, перевод, визуализация перевода через AR и взаимодействие компонентов. Рассмотрим их более подробно.

– Захват речи. Клиентская часть системы должна обеспечивать функциональность захвата аудиосигнала с микрофона устройства. Это является основным входом для дальнейшей обработки и перевода речи.

Основные требования:

– Автоматическое начало записи: приложение должно автоматически начать запись речи пользователя при активации функции перевода.

– Поддержка различных языков: система должна уметь распознавать речь на нескольких языках.

– Качество захвата: приложение должно минимизировать влияние фонового шума и обеспечивать чёткую запись даже в условиях громких звуков.

– Продолжительность записи: захват речи должен быть гибким и позволять пользователю говорить в течение длительного времени (например, до 30 секунд) без прерывания.

– Перевод текста. Клиентская часть системы выполняет перевод текста и аудио, вводимых пользователем. Это требует использования алгоритмов машинного обучения и нейронных сетей, которые должны обеспечивать высокое качество перевода в реальном времени. Основные требования:

– Использование нейросетевых моделей: клиент должен использовать предобученные автономные модели машинного перевода для перевода текста и речи на одном языке в текст на другом языке.

- Поддержка нескольких языков: система должна поддерживать несколько языковых пар, что позволяет переводить речи с разных языков, например, с английского на русский, с немецкого на английский и других.

- Высокая точность перевода: важным требованием является минимизация ошибок перевода, особенно в контексте технических терминов и фраз.

- Реальное время: перевод должен выполняться в реальном времени с минимальной задержкой, чтобы пользователь мог получить переведённый текст почти сразу после произнесения фразы.

- Передача и обработка OCR-изображений на сервере. Клиентская часть системы захватывает кадры с камеры или готовые изображения и отправляет их на сервер для оптического распознавания текста (OCR). Обработка на сервере позволяет задействовать полнофункциональные нейросетевые модели и обеспечивать высокое качество распознавания даже в сложных условиях.

Основные требования:

- Использование нейросетевых моделей OCR. Сервер должен применять предобученную конвейерную модель PaddleOCR, включающую три этапа — детектирование зон текста, классификацию ориентации и собственно распознавание символов.

- Поддержка разнообразных шрифтов и языков. Система обязана корректно обрабатывать тексты на разных алфавитах (латиница, кириллица, иероглифы и т. д.) и адаптироваться к широкому спектру шрифтов, размеров и ориентаций текста.

- Высокая точность извлечения. Минимизация пропусков символов и артефактов особенно важна при работе с технической документацией или низкокачественными изображениями. Ошибки на этапе OCR могут привести к искажениям при последующем переводе.

- Низкая задержка обработки. Весь цикл передачи кадра, OCR-распознавания и получения результата должен укладываться в рамки нескольких сотен

миллисекунд, чтобы интерфейс оставался отзывчивым и не мешал потоковому переводу.

- Сохранение структурной информации. Помимо чистого текста, сервер должен возвращать координаты и размеры текстовых блоков, что позволяет клиенту в AR-интерфейсе точно позиционировать субтитры или аннотации на исходном изображении.

- Взаимодействие компонентов. Все компоненты системы (клиент, сервер, AR-модуль) должны эффективно взаимодействовать между собой.

Основные требования:

- Обмен данными между клиентом и сервером: клиентская и серверная части должны использовать стандартные протоколы (например, HTTP, WebSocket) для передачи аудиофайлов, текстов и ответов сервера.

- Безопасность передачи данных: для защиты данных пользователей (например, их речи) должна быть обеспечена безопасная передача данных с использованием шифрования.

- Обработка ошибок и исключений: система должна правильно обрабатывать ошибки, например, при потере соединения, слишком длительной задержке перевода или несоответствии формата данных.

- Оптимизация работы в реальном времени: система должна работать быстро, эффективно и без сбоев. Например, задержка между произнесением фразы и отображением переведённого текста не должна превышать несколько секунд.

- Дополнительные требования.

Перечислим следующие требования:

- Эргономичный интерфейс пользователя: приложение должно быть простым в использовании, с интуитивно понятным интерфейсом для настройки перевода и AR-функции.

- Многоязычность интерфейса: интерфейс приложения должен поддерживать несколько языков, позволяя пользователям выбрать нужный для работы.

3.2 Практическая реализация программы

3.2.1 Архитектура разработанной системы

Разработанная система синхронного перевода речи представляет собой многослойное приложение, выполненное по классической клиент-серверной модели с чётким разделением зон ответственности и возможностью автономной работы части функций в оффлайн-режиме. Ниже приводится описание структурной схемы программного продукта и пояснения по ключевым блокам.

Разберем структурную схему программы:

– Уровень презентации (Presentation):

– MainActivity управляет навигацией между фрагментами.

– VoiceTranslateFragment обрабатывает ввод аудио и инициирует перевод.

– ArTranslateFragment отображает результаты перевода в AR-сцене.

– Уровень бизнес-логики (Domain):

– СетевойКлиент реализует протокол передачи данных (WebSocket / REST).

– МенеджерПеревода инкапсулирует логику преобразования текста.

– OCRПроцессор выполняет клиентское извлечение текста из изображений.

– Уровень данных (Data):

– КонтроллерAPI маршрутизирует запросы на серверные микросервисы.

– МодульПеревода, СерверныйOCR, ГенераторARИзображений и МенеджерДанных реализованы как Docker-контейнеры, взаимодействующие через REST / gRPC / Redis.

– Кэш / SQLite хранит локальные копии переводов и настройки пользователя.

– Инфраструктурный уровень:

– ONNX-модели (Whisper, MarianMT, PaddleOCR) развёрнуты в ONNX Runtime на GPU-нодах.

- Redis обеспечивает межсервисный кэш и очередь заданий.
- Uvicorn поднимает FastAPI-приложение в асинхронном режиме.

Теперь рассмотрим построенные артефакты, такие как диаграмма компонентов. Диаграмма компонентов используется для отображения архитектуры программной системы на более высоком уровне. Она показывает на рисунке 6, из каких основных компонентов состоит система и как они взаимодействуют между собой. Это удобно для понимания общей структуры и деления системы на логические модули.

Диаграмма компонентов:

- Демонстрирует физические модули системы (клиентский UI, сетевой клиент, API-контроллер, OCR, MT, AR-рендеринг, менеджер данных) и их зависимости.
- Позволяет увидеть, как контейнеры разворачиваются и какие интерфейсы реализуют.




Рисунок 6 – Диаграмма компонентов

В системе синхронного перевода речи с поддержкой машинного обучения и дополненной реальности выделяются два ключевых уровня:

- Клиентский уровень (Android-приложение), который включает:
 - Графический интерфейс (UI Controller) управляет навигацией и взаимодействием пользователя: выбором исходного и целевого языков, запуском и остановкой перевода, настройкой параметров отображения.
 - OCR-пакет (OCR Package) исполняет локальное извлечение текста из неподвижных кадров или ключевых фреймов видеопотока (с помощью PaddleOCR или ML Kit), позволяя работать в оффлайн-режиме.
 - Модуль СетевойКлиент (Network Client). Осуществляет двустороннюю связь с сервером:
 - Передаёт на сервер JPEG/PNG-кадры или потоки аудиофреймов по WebSocket/REST.
 - Принимает обратно либо переведённый текст, либо готовые AR-кадры.
 - Модуль Перевод (Translation Manager):
 - Управляет последовательностью локальных и удалённых переводов.
 - Запускает клиентский ML Kit или ONNX-модели для простого оффлайн-перевода.
 - При наличии сети передаёт запрос на серверный Translation Module и обрабатывает результат.
 - Просмотр (AR Viewer):
 - Накладывает текстовые или графические аннотации на видеопоток камеры в реальном времени с помощью ARCore/Sceneform.
 - Принимает результат от Network Client.
 - Создаёт AR-объекты, привязанные к плоскостям и геометрии сцены.
 - Поддерживает интерактивную настройку масштаба, прозрачности и положения текста.

- Серверный уровень (Backend) включает следующие модули:
 - Модуль APIКонтроллер (API Controller). Принимает входящие запросы от клиента по REST и WebSocket, проверяет параметры, распределяет задачи по микросервисам и собирает результаты.
 - Модуль OCR (OCR Service). Получает из API Controller изображение, передаёт их во внутренний ONNX-пайплайн (detection → classification → recognition) и возвращает распознанный текст.
 - Модуль Перевод (Translation Service). Принимает строку из OCR-модуля, запускает MarianMT-ONNX для контекстно-осознанного перевода и возвращает результат API Controller.
 - Модуль Управление Данными (Data Manager). Логирует все операции, управляет кэшем (Redis) распознанных фрагментов и переводов, хранит историю сессий и ошибок.
 - ONNX-модели (Artifact). Включают Whisper (ASR), MarianMT (MT) и PaddleOCR, развёрнутые в ONNX Runtime на GPU/CPU-нодах.
- Последовательность взаимодействия:
 - Клиент собирает кадр или аудиофрейм → OCR-пакет (при оффлайн-распознавании) или напрямую → Network Client.
 - Network Client отправляет фрейм и параметры перевода (source_lang, target_lang) → API Controller.
 - API Controller направляет изображение в OCR-модуль → получает текст T.
 - API Controller передаёт T → Translation Module → получает перевод T'.
 - API Controller сохраняет T / T' в Data Manager, формирует готовый AR-кадр через GeneratorARImages и возвращает его → Network Client.
 - Client AR Viewer визуализирует полученный кадр поверх видеопотока.

Таким образом, двухуровневая архитектура с чётким разграничением клиентских и серверных обязанностей обеспечивает минимальную задержку, масштабируемость и возможность оффлайн-работы ключевых компонентов.

Диаграмма классов. Ниже приводится описание ключевых классов клиентской и серверной частей системы, их основных свойств, методов и типов связей. Графически диаграмма представлена на рисунке 7.




Рисунок 7 – Диаграмма классов

– Клиентская часть состоит из:

– MainActivity (ГлавнаяАктивность). Точка входа в приложение, отвечает за инициализацию и переключение между экранами (FragmentManager). Ассоциирована с обоими фрагментами: ФрагментПереводаРечи и ФрагментARПеревода.

– ФрагментПереводаРечи. В качестве основных полей было выбрано состояние микрофона включенаЗапись: Boolean. В качестве метода аудио-

захвата через `AudioRecord` — начать `Запись()`, для вывода полученного текста в UI — отобразить `Перевод()`.

– `ФрагментARПеревода`. Отвечает за визуализацию переведённого текста в дополненной реальности. Использует AR-интерфейс для наложения текста на изображение с камеры. В качестве основного свойства используется изображение: `Bitmap` — кадр, на который будет наложен перевод. Метод `получитьИзображение()` запрашивает готовый AR-кадр у `СетевойКлиент`, а `отобразитьТекст()` формирует AR-аннотацию с использованием компонента `ARОтображение`. Связан с `OCRПроцессор` при оффлайн-работе (использует) и получает визуализированные данные от `ARОтображение` (отрисовывает).

– `СетевойКлиент`. Обеспечивает взаимодействие мобильного клиента с сервером по протоколам `WebSocket/REST`. Основное свойство — `адресСервера: String`, содержащее IP и порт удалённого сервера. Методы `подключитьсяКСерверу()`, `отправитьИзображение()` и `получитьИзображение()` отвечают за установление соединения и передачу данных. Делегирует операции перевода компоненту `МенеджерПеревода` (делегирует) и обменивается данными с `КонтроллерAPI` (`communicates`).

– `МенеджерПеревода`. Обрабатывает текстовые данные после OCR или при получении с сервера. Метод `перевестиТекст(text: String): String` реализует либо локальный ML-перевод, либо пересылает текст на сервер. Метод `обработатьРезультат()` нормализует, кэширует и подготавливает данные к визуализации.

– `OCRПроцессор`. Отвечает за локальную обработку изображения и извлечение текста. Метод `обработатьИзображение()` выполняет предобработку (фильтрация, коррекция ориентации), а `извлечьТекст()` применяет `PaddleOCR` для распознавания текста. Результат передаётся на `ARОтображение` для отрисовки (отрисовывает).

– `ARОтображение`. Участвует в финальной визуализации перевода в дополненной реальности. Метод `нарисоватьТекст(text: String)` создаёт AR-

аннотацию, а обновить Вид() отвечает за реакцию на движение устройства и адаптацию отображения.

– Серверная часть включает:

– Контроллер API. Главный компонент backend-приложения, принимающий запросы от клиента. Метод обработатьЗапрос() обеспечивает приём фреймов по REST/WebSocket, а маршрутизировать() распределяет задачи между микросервисами: OCR, перевод, визуализация.

– Серверный OCR. Микросервис для распознавания текста на изображении. Метод распознатьТекст() обращается к ONNX-моделям, выполняющим детектирование, классификацию и извлечение текста.

– Модуль Перевода. Выполняет перевод текста между языками. Метод перевести (text: String): String вызывает ONNX-модель MarianMT, обеспечивая контекстный и точный машинный перевод.

– Генератор AR Изображений. Создаёт визуализированные изображения с AR-аннотациями. Метод наложитьПеревод() формирует PNG-файл с текстом, встроенным в исходное изображение, с учётом перспективы и координат.

– Менеджер Данных. Управляет логами и временными файлами. Метод сохранитьВременныеДанные() кэширует промежуточные результаты (Redis), управлять Логами() ведёт учёт ошибок, сессий и статистики.

– Типы связей:

– Ассоциация (→): постоянная зависимость (например, MainActivity → Фрагменты). Использование (uses): вызов сервисов или методов (например, Фрагмент AR Перевода использует OCR Процессор).

– Делегирование (делегирует): передача ответственности (например, Сетевой Клиент делегирует → Менеджер Перевода).

– Визуализация (отрисовывает): передача результата визуализации (OCR Процессор отрисовывает → AR Отображение).

Таким образом, диаграмма классов чётко разграничивает роли компонентов, их интерфейсы и взаимодействия, что облегчает сопровождение, тестирование и дальнейшее расширение системы.

3.2.2 ER-модель данных

ER-модель (Entity-Relationship-модель) описывает логическую структуру базы данных, отражающую взаимосвязи между ключевыми сущностями в разработанной системе синхронного перевода речи. Построенная модель обеспечивает нормализованное хранение информации о пользователях, сессиях перевода, текстовых фрагментах, кэше и ошибках, представлена на рисунке 8.




Рисунок 8 – ER-Диаграмма

Ниже представлены основные сущности, их атрибуты и связи.

– Сущность Пользователь. Содержит данные зарегистрированных пользователей системы. Уникальный идентификатор `id_пользователя` используется как первичный ключ и связывается с другими сущностями. Среди атрибутов имеет только:

– `id_пользователя`: INT — первичный ключ (PK).

– Сущность СессияПеревода. Отражает отдельные сессии перевода, инициированные пользователем. Каждая сессия связана с конкретным пользователем и включает параметры языков. Атрибуты:

– `id_сессии`: INT — первичный ключ (PK).

– `id_пользователя`: INT — внешний ключ (FK) на сущность Пользователь.

– `дата_время`: DATETIME — время начала сессии.

– `язык_источника`: VARCHAR — исходный язык.

– `язык_перевода`: VARCHAR — целевой язык.

Связь: Один пользователь может иметь несколько сессий (1:N).

– Сущность ФрагментПеревода содержит отдельные фрагменты текста, полученные и переведённые в рамках одной сессии. Атрибуты:

– `id_фрагмента`: INT — первичный ключ (PK).

– `id_сессии`: INT — внешний ключ (FK) на СессияПеревода.

– `исходный_текст`: TEXT — оригинальный текст.

– `переведённый_текст`: TEXT — переведённая версия.

– `время_фрагмента`: DATETIME — время фиксации фрагмента.

Связь: Каждая сессия может включать множество фрагментов (1:N).

– Сущность Кэш отражает механизм кэширования результатов перевода для оптимизации повторной обработки.

Атрибуты:

– `id_кэша`: INT — первичный ключ (PK);

– `id_фрагмента`: INT — внешний ключ (FK) на ФрагментПеревода;

– `дата_создания`: DATETIME — время кэширования.

Связь: Один фрагмент может иметь несколько кэш-записей, например, при изменении параметров отображения (1:N).

– Сущность Ошибка используется для хранения информации об ошибках, возникших при работе пользователя с системой.

Атрибуты:

- id_ошибки: INT — первичный ключ (PK);
- id_пользователя: INT — внешний ключ (FK) на Пользователь;
- код_ошибки: VARCHAR — внутренний или стандартный код ошибки;
- описание: TEXT — текстовое описание причины;
- timestamp: DATETIME — дата и время возникновения ошибки.

Связь: Один пользователь может быть источником нескольких ошибок (1:N).

Модель спроектирована в третьей нормальной форме (3NF), что исключает дублирование данных и минимизирует избыточность. Использование первичных и внешних ключей обеспечивает целостность данных между таблицами. ER-модель обеспечивает логически обоснованное и масштабируемое хранение информации, необходимой для работы системы перевода, включая учёт пользовательской активности, хранение результатов перевода и диагностику ошибок.

3.2.3 Механизм захвата и передачи данных между клиентом и сервером

В разрабатываемой системе синхронного перевода речи с использованием машинного обучения и дополненной реальности ключевую роль играет надёжный и эффективный механизм захвата, сериализации и передачи данных от клиентского устройства к серверу и обратно. Он должен соответствовать требованиям к задержке, пропускной способности, сжатию и устойчивости соединения в условиях мобильной среды. Ниже представлена реализованная архитектура обмена данными и её особенности.

– Захват изображения на клиенте. Для визуального потока используется библиотека CameraX, которая обеспечивает извлечение кадров в формате Bitmap с последующей сериализацией в PNG или JPEG (в зависимости от настроек ка-

чества). Кадры, извлекаемые с камеры мобильного устройства с помощью библиотеки CameraX, проходят обязательный этап предобработки, направленный на снижение сетевой нагрузки и улучшение качества распознавания текста на серверной стороне (OCR). Обработка включает несколько стадий:

- Обрезка (cropping). После получения исходного изображения (в формате YUV_420_888 и RGBA), применяется операция обрезки (crop) по заранее заданной области интереса (Region of Interest, ROI). Эта область вычисляется динамически (на основе предобученной ML-модели для выделения текста). Цель: исключить излишние элементы (фон, руки, объекты вне фокуса), минимизируя ненужный трафик и улучшая точность OCR.

- Масштабирование (resizing). Обрезанный фрагмент масштабируется до стандартного разрешения, чаще всего в диапазоне 640x480 или 800x600, что обеспечивает компромисс между качеством и объёмом данных. Масштабирование производится с сохранением пропорций (aspect ratio) с помощью метода OpenCV.resize().

- Кодирование. После обрезки и масштабирования изображение сериализуется в формат JPEG. Он используется при необходимости максимального сжатия. Применяется параметр quality (обычно 70–85%) для снижения размера файла при приемлемом качестве. А затем в формат Base64 для WebSocket. В случае WebSocket передача предпочтительно осуществляется в бинарном виде (ByteBuffer) без дополнительной сериализации, что снижает накладные расходы.

- Метаданные. Вместе с изображением передаются вспомогательные данные как на рисунке 9.

```
{
  "session_id": "abc-123",
  "frame_type": "image",
  "data": "<binary>",
  "source_lang": "en",
  "target_lang": "ru",
  "timestamp": 1718002930000
}
```

Рисунок 9 – Передаваемые метаданные

Передаваемые параметры включают в себя: уникальный идентификатор сессии, тип кадра, тип данных, исходный и целевой язык, и таймстемп кадра (метка времени).

- Предобработка данных. Изображения проходят через OpenCV-фильтры для выравнивания, бинаризации и повышения контрастности — эти операции необходимы для более точного OCR.

- Кодирование и сериализация. Изображения сериализуются в Base64 или передаются в виде бинарных массивов по WebSocket в зависимости от уровня поддержки на клиентском устройстве.

- Передача данных на сервер. Передача данных реализована через двустороннее соединение WebSocket (okhttp + kotlin.coroutines), обеспечивающее низкую латентность (задержку), поддержку асинхронного обмена, возможность стриминга данных (streaming upload/download).

- Обработка на сервере. На стороне сервера реализован асинхронный API на базе FastAPI + Uvicorn, принимающий данные по маршрутам WebSocket и REST. Полученные изображения и файлы метаданных передаются в соответствующие микросервисы:

- OCR (PaddleOCR, ONNX).

- MT (MarianMT-ONNX).

- AR-реконструкция (OpenCV + PIL).

После обработки результат (переведённый текст, метаданные, AR-слои) агрегируется и возвращается клиенту в виде JSON или изображения с наложенным текстом (AR-кадр).

- Обратная передача и отображение. На клиенте полученное изображение транслируется с наложенным текстом перевода.

Реализованный механизм обмена данными обеспечивает баланс между производительностью, качеством обработки и стабильностью при работе в мобильной среде. Использование WebSocket, сжатия, предварительной фильтрации и coroutine-архитектуры позволяет добиться отклика, близкого к real-time, при сохранении высококачественного перевода и визуализации.

3.2.4 Серверная обработка изображения, перевода и AR-визуализации

Серверная часть приложения реализует полный конвейер обработки изображения: от распознавания текста (OCR) до генерации визуализированного результата в формате AR-кадра. Архитектура построена по микросервисному принципу, где каждая стадия обработки выделена в отдельный сервис, взаимодействующий через асинхронные API и очередь задач.

– Получение изображения. После захвата изображения на клиенте оно сжимается (JPEG/PNG), масштабируется и кодируется в base64 либо бинарно, после чего передаётся на сервер по WebSocket-соединению. Одновременно с изображением передаются параметры конфигурации (метаданные).

Получателем является API-контроллер — фасадный компонент, отвечающий за маршрутизацию данных между микросервисами.

– Распознавание текста (OCR). Изображение передаётся в OCR-сервис, построенный на базе библиотеки PaddleOCR, поддерживающей три последовательных этапа:

– Detection — обнаружение текстовых блоков с помощью ONNX-модели на базе DBNet.

– Classification — определение ориентации текста (поворот, зеркалирование).

– Recognition — извлечение текста из фрагментов с использованием CRNN-модели, оптимизированной под ONNX Runtime.

Сервис возвращает список распознанных строк на примере изображения с рисунка 10.




Рисунок 10 – Пример OCR-распознавания на примере документа с текстом

– Перевод текста. Распознанные строки передаются в модуль перевода, использующий модель MarianMT (в формате ONNX) для выполнения нейросетевого перевода. Сервис:

- принимает массив строк;
- применяет батчинг (обработка нескольких фраз за один вызов);
- возвращает массив переведённых фрагментов, сопоставимых по индексу.

Модель MarianMT была выбрана за поддержку множества языков и устойчивость к коротким и неформальным выражениям. Используется постобработка перевода:

- нормализация регистра;
- коррекция пунктуации;
- фильтрация нежелательных символов.

– Генерация AR-визуализации. На следующем этапе данные направляются в AR-рендеринг-сервис, который принимает:

- оригинальное изображение;
- координаты текстовых блоков;
- переведённый текст.

Результатом является AR-кадр в формате PNG/JPEG, содержащий переведённый текст, встроенный поверх оригинальной сцены рисунок 11.

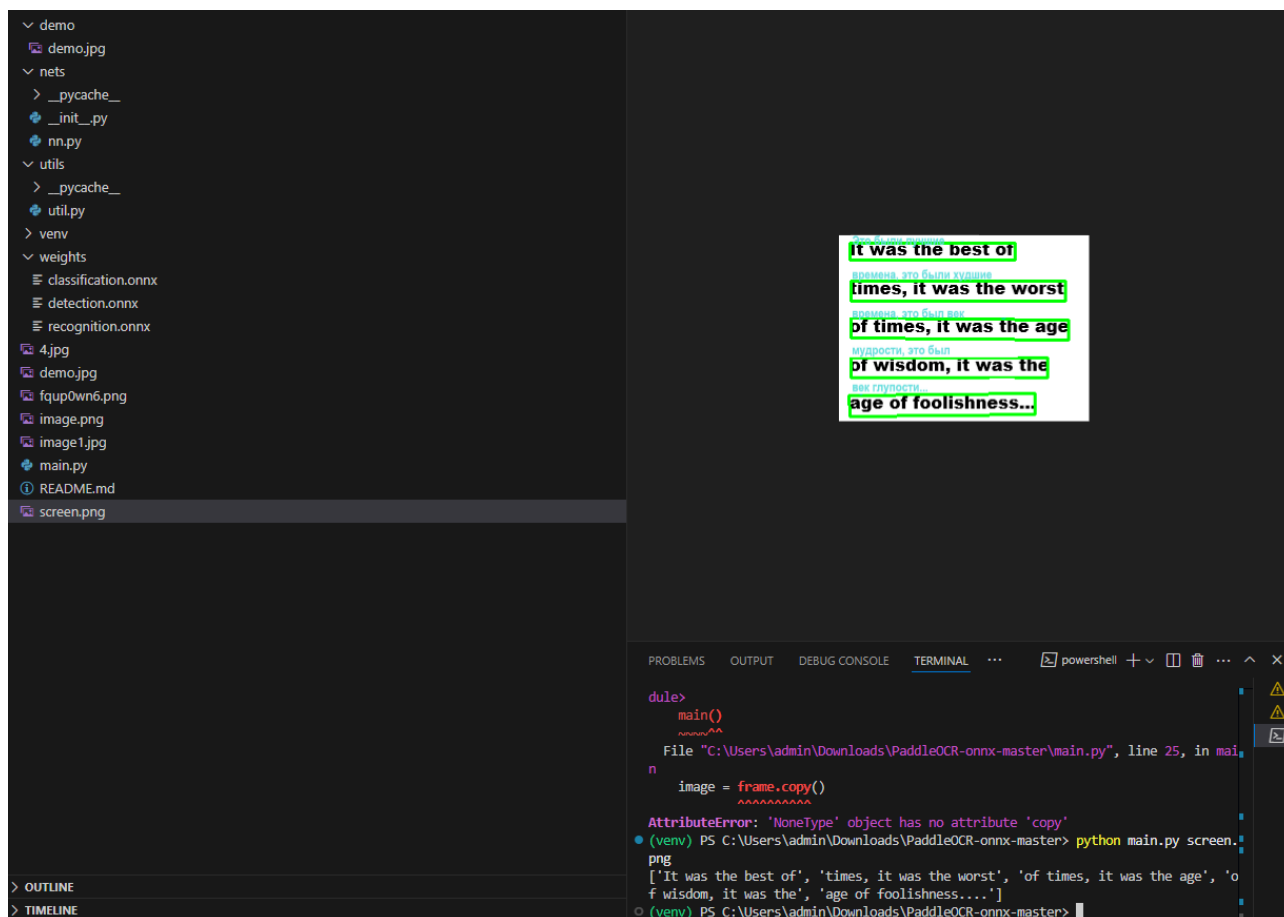


Рисунок 11 – Снимок экрана перевода фрагмента изображения

– Возврат результата. Финальное изображение (AR-кадр) передаётся обратно клиенту через WebSocket с минимальной буферизацией. Также может быть возвращён альтернативный текст в JSON-формате — для отображения через локальные AR-компоненты на устройстве.

– Архитектурные особенности. Контейнеризация: каждый сервис работает в отдельном Docker-контейнере и может быть масштабирован независимо (OCR, MT, AR).

– ONNX Runtime: используется как единая среда исполнения нейросетевых моделей на CPU/GPU.

– Redis: применяется для кэширования перевода, хранения сессий и логирования ошибок.

– FastAPI + Uvicorn: обеспечивает высокопроизводительный API-уровень с поддержкой асинхронной обработки и WebSocket.

Таким образом, сервер реализует эффективный, модульный и масштабируемый пайплайн для обработки изображений и генерации AR-визуализации с использованием современных ML-технологий. Это позволяет добиться высокой точности перевода и минимальной задержки при отображении результатов на мобильном клиенте.

3.2.5 Архитектура асинхронного взаимодействия на Kotlin и FastAPI

Система синхронного перевода речи и текста с дополненной реальностью реализует двустороннюю асинхронную коммуникацию между клиентом (Android-приложение на Kotlin) и сервером (FastAPI-приложение на Python). Архитектура построена по принципам событийной обработки и неблокирующих операций, что критично для приложений реального времени.

– Асинхронность на стороне клиента (Kotlin + Coroutines). Мобильное приложение использует Kotlin coroutines и библиотеку Flow для построения неблокирующих цепочек обработки данных. Каждое ключевое действие (захват изображения, передача, приём результата) оформлено как suspend-функция и выполняется в отдельных coroutine-контекстах (IO, Default, Main).

Ключевые особенности:

– CaptureWorker: реализует захват кадров с камеры через CameraX и передаёт их через канал Channel <Image>.

– WebSocketClient: управляет подключением и передачей сообщений с использованием библиотеки OkHttp WebSocket. Входящие и исходящие сообщения обрабатываются через Flow.

– TranslationPipeline: объединяет цепочку захвата изображения, его передачи, ожидания ответа и визуализации.

– Асинхронность на стороне сервера (FastAPI + asyncio). Серверная часть реализована на FastAPI — современном Python-фреймворке, построенном на asyncio, и использует ASGI-сервер Uvicorn. Это позволяет обрабатывать десятки тысяч одновременных соединений с минимальной задержкой.

Основные особенности:

- Обработка WebSocket-соединений с использованием @websocket-роутов. Каждое соединение поддерживает двустороннюю передачу изображений и AR-результатов.

- Использование async def-обработчиков и await для всех операций: загрузка изображений, вызов моделей, сбор AR-кадров.

- Параллельная маршрутизация задач в микросервисы OCR, MT и AR-рендерера с помощью очередей (asyncio.Queue) или Redis Pub/Sub.

- Связь между клиентом и сервером. Имеет следующие особенности:

- Передача кадров осуществляется по WebSocket-соединению, открытому клиентом в фоновом режиме.

- На каждый отправленный кадр сервер возвращает отрендеренное изображение, либо структуру с координатами и переведённым текстом.

- Все операции выполняются асинхронно, что исключает блокировки UI на клиенте и снижает нагрузку на сервер.

- Преимущества архитектуры:

- Низкая задержка (latency): данные обрабатываются по мере поступления, без необходимости ждать завершения других операций.

- Высокая масштабируемость: при использовании FastAPI + Uvicorn сервер обслуживает тысячи соединений параллельно без блокировок.

- Гибкая обработка ошибок: coroutine-цепочки позволяют перехватывать ошибки на любом этапе и обеспечивать отказоустойчивость.

- Разгрузка клиента: основная ML-обработка вынесена на сервер, а клиент занимается только захватом и визуализацией.

Таким образом, архитектура асинхронного взаимодействия, реализованная с использованием Kotlin Coroutines на клиенте и FastAPI с asyncio на сервере, позволяет обеспечить высокую отзывчивость системы, устойчивую работу в реальном времени и эффективную обработку мультимодальных данных.

3.2.6 Интерфейс пользователя и отображение перевода в AR-сцене

Интерфейс пользователя (UI) в разработанном мобильном приложении ориентирован на минимализм, интуитивность и удобство взаимодействия при

выполнении задачи синхронного перевода с использованием технологий дополненной реальности. Основной упор сделан на гибкую настройку параметров перевода и беспрепятственное восприятие результата в AR-пространстве в реальном времени.

Приложение разработано с использованием Jetpack Compose, что обеспечивает декларативный подход к созданию UI и упрощает реактивную обработку состояний.

Основные экраны пользовательского интерфейса:

- Домашний экран. Позволяет пользователю выбрать исходный и целевой языки перевода. Доступны два режима: текстовый перевод и распознавание речи с последующим преобразованием в текст.

- Экран диалога. Активирует модуль захвата аудио. Оба участника диалога могут задать свой язык ввода и получения перевода, что упрощает общение между носителями разных языков. Данный режим поддерживает распознавание длинных фраз и может эффективно работать в автономном (офлайн) режиме.

- Экран AR-перевода. Отображает изображение с камеры устройства в реальном времени. Пользователь выбирает языки распознавания и перевода, затем делает фото — приложение возвращает изображение с наложенным переведённым текстом в AR-формате.

Особенности реализации. Работа с AR реализована с учётом ограничений производительности мобильных устройств. Все ресурсоёмкие операции, включая позиционирование текста, масштабирование и форматирование, выполняются в отдельных потоках с использованием coroutines и Flow, что обеспечивает плавность интерфейса и отсутствие блокировки основного UI-потока.

Визуализация текста осуществляется средствами ARCore + Sceneform с применением ViewRenderable, AnchorNode и библиотеки CameraX для работы с видеопотоком камеры. Координаты наложения текста формируются либо на основе OCR, либо выбираются вручную пользователем, что позволяет точно интегрировать перевод в сцену.

Таким образом, интерфейс приложения обеспечивает полный цикл взаимодействия — от выбора параметров перевода до визуального представления результата. Продуманный дизайн и техническая реализация позволяют пользователю не отвлекаться от реального окружения и получать результат максимально естественно, быстро и удобно.

3.2.7 Пример пользовательского сценария работы системы

Ниже описан типовой сценарий использования мобильного приложения синхронного перевода речи с дополненной реальностью (AR). Для каждого этапа приведён рекомендуемый рисунок, иллюстрирующий соответствующий экран или поведение приложения.

– Запуск приложения. Пользователь запускает приложение на устройстве с поддержкой ARCore.

Инициализируется MainActivity и связывает пользовательский интерфейс с логикой. На рисунке 12 можно ознакомиться со снимком экрана домашнего экрана.




Рисунок 12 — Заставка и экран запуска приложения (MainActivity)

– Настройка параметров перевода на домашнем экране. На домашнем экране пользователь выбирает параметры сессии:

- исходный язык (например, английский);
- целевой язык (русский);
- режим перевода: перевести введенный текст или голосовой ввод.




Рисунок 13 — Интерфейс выбора языков и режима перевода

– Выбор модулей перевода из бокового меню. Открыв боковое меню на рисунке 14, пользователь может выбрать один из предоставленных типов перевода.



Рисунок 14 — Боковое меню программы

– Голосовой режим. Перейдя на соответствующий экран программы на рисунке 15 пользователь может воспользоваться режимом перевода для беседы с носителем другого языка. Было решено создать 4 спинера с выбором языков для обоих пользователей, чтобы минимизировать количество нажатий и упростить интерфейс для удобного взаимодействия с программой. Результат можно увидеть на экране.




Рисунок 15 — Экран голосового режима перевода

Далее выбрав необходимые языки перевода, следует запустить микрофон и оценить распознавание голоса, который представлен на рисунке 16.




Рисунок 16 — Экран голосового режима перевода

Реализована эта функция с помощью библиотеки ML Kit. Пользователь произносит тестовую фразу на английском языке, заранее выбрав этот язык в списке. Таким образом был реализован следующий функционал:

- захват речи;
- обработка результата;
- перевод текста. Представлен на рисунке 17;
- реализована асинхронность.

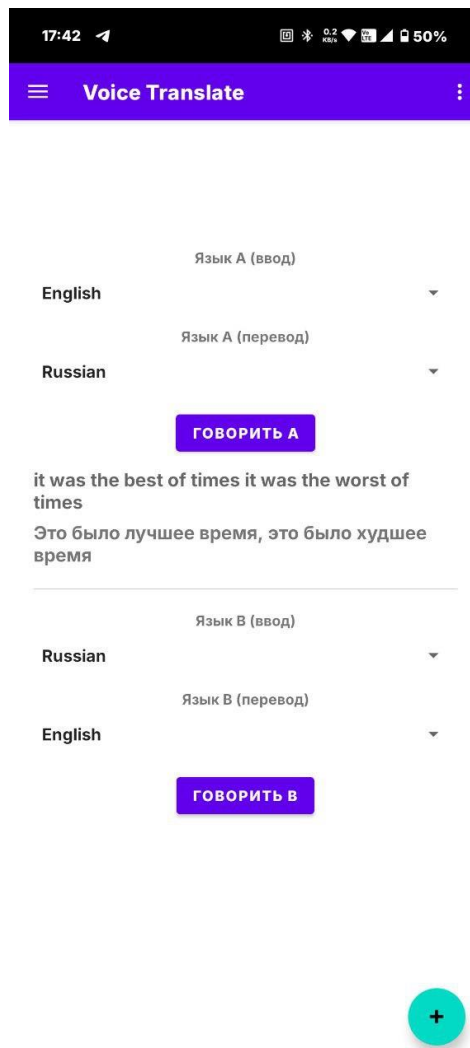


Рисунок 17 — Перевод тестовой фразы

– Захват данных:

– ARОтображение активирует AR-сцену через CameraX.

– OCRПроцессор и МенеджерПеревода загружают модели для локальной обработки (ONNX / ML Kit).

После настройки пользователь нажимает кнопку «Перевести» в AR-режиме, представленном на рисунке 18:

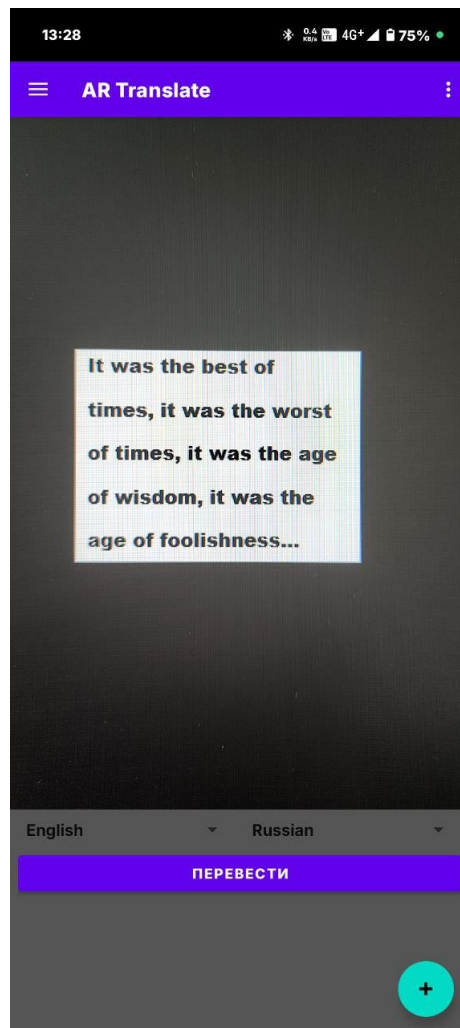


Рисунок 18 — AR-режим перевода

Внутри логики программы:

- Активируется CameraX, производится захват кадра.
- Кадр передаётся в OCRПроцессор для извлечения текста (опционально — при локальной обработке).
- Далее изображение и языковые параметры передаются на сервер через СетевойКлиент по WebSocket.

На выходе после нажатия кнопки перевести получаем перевод на рисунке 19.

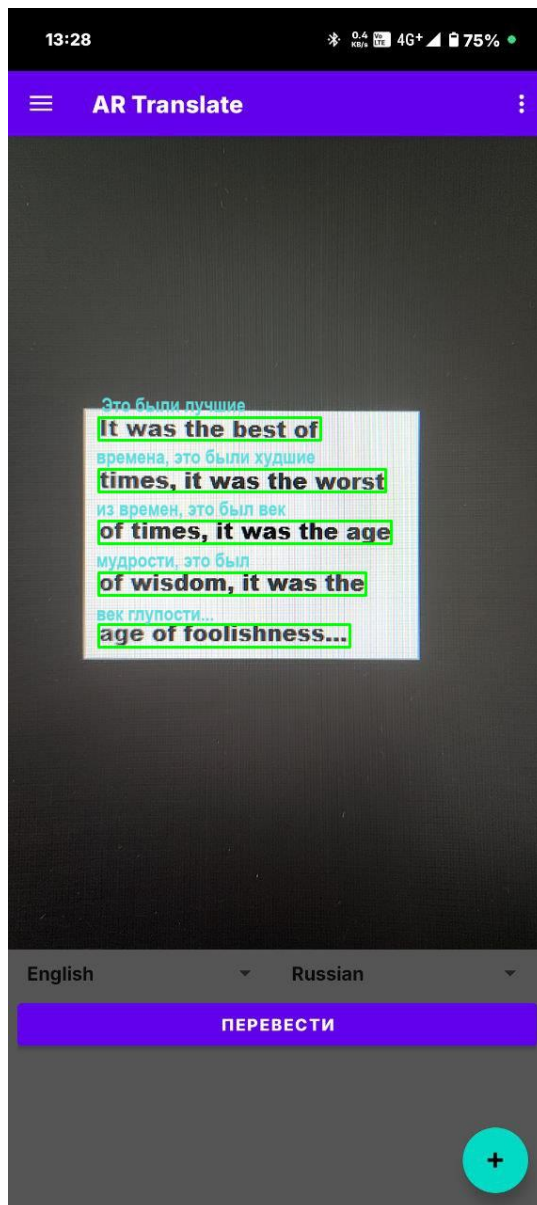


Рисунок 19 — перевод тестовой картинки с помощью MarianMT и PaddleOCR

Вся информация (включая ошибки и метаданные) логируется через Менеджер Данных и может быть сохранена в Redis.

Такой подход позволяет обеспечить стабильную работу системы в режиме реального времени и предоставляет пользователю полноценный AR-опыт в любом месте с минимальными техническими требованиями.

3.2.8 Оценка производительности и сценарии масштабирования

Для оценки производительности разработанного приложения были проведены тесты, позволяющие понять, насколько быстро и стабильно работает система при различных условиях.

В частности, проверялись:

- скорость обработки аудио и перевода текста;
- время отклика между клиентом (мобильное приложение) и сервером.

Результаты показали, что при стандартной нагрузке (1–2 пользователя) система работает стабильно: задержка между распознаванием речи и отображением переведённого текста составляет в среднем 1.2–1.5 секунды. Это является допустимым для большинства сценариев использования.

Потенциальные сценарии масштабирования:

- Вынос тяжёлых операций (например, перевода или распознавания речи) в отдельные микросервисы, которые можно разворачивать отдельно и масштабировать независимо.
- Кеширование часто используемых переводов — позволит уменьшить нагрузку на сервер при повторных запросах одних и тех же фраз.

ЗАКЛЮЧЕНИЕ

В ходе выполнения магистерской диссертации была достигнута поставленная цель — разработано приложение синхронного перевода речи с использованием технологий машинного обучения и дополненной реальности (AR), обеспечивающее удобное взаимодействие с пользователем, высокую скорость и приемлемую точность перевода.

Для достижения цели были решены следующие задачи:

- Проведён обзор современных технологий и подходов, применяемых в области синхронного перевода речи, включая алгоритмы распознавания аудио, нейросетевые модели перевода и принципы построения AR-интерфейсов.

- Проанализированы способы объединения машинного обучения и дополненной реальности в рамках одного приложения, рассмотрены технические и концептуальные особенности их интеграции.

- Разработана архитектура программной системы, включающая мобильный клиент (захват и распознавание речи, машинный перевод) и серверную часть (распознавание текста на изображении, визуализация перевода в AR).

- Реализован работающий прототип приложения и проведена его оценка по ключевым параметрам: время отклика, точность перевода, нагрузка на систему, качество отображения в AR.

- Разработка показала, что сочетание ML и AR даёт возможность создать эффективное средство для перевода речи в реальном времени с наглядным отображением результата.

В будущем планируется:

- Расширить количество поддерживаемых языков.

- Интегрировать более продвинутые модели перевода.

Полученные результаты подтверждают перспективность использования AR и машинного обучения в разработке современных систем перевода, повышающих удобство и доступность общения между людьми, говорящими на разных языках.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

- 1 Абдуллаев, А. Р. Машинное обучение: основы и применение : моногр. / А. Р. Абдуллаев, В. П. Иванов. – 2-е изд., перераб. и доп. – М. : Техносфера, 2021. – 320 с.
- 2 Андреев, А. М. Обработка естественного языка: методы и алгоритмы : моногр. / А. М. Андреев, С. К. Петров. – М. : Лань, 2020. – 256 с. – ISBN 978-5-8114-4567-9.
- 3 Белов, А. А. Дополненная реальность: технологии и применение : моногр. / А. А. Белов. – СПб. : Питер, 2019. – 180 с. – ISBN 978-5-4461-1234-5.
- 4 Бенчмарк систем машинного перевода [Электронный ресурс] // Machine Translation Benchmark. – Режим доступа : <https://www.machinetranslation.com/ru/blog/translation-engines-benchmark> . – 14.03.2025.
- 5 Борисов, Н. В. Нейронные сети и глубокое обучение : моногр. / Н. В. Борисов, И. А. Кузнецов. – М. : ДМК Пресс, 2022. – 400 с. – ISBN 978-5-97060-789-0.
- 6 Васильев, В. И. Машинное обучение на Python: практическое руководство : моногр. / В. И. Васильев. – М. : БХВ-Петербург, 2021. – 352 с. – ISBN 978-5-9775-6789-0.
- 7 Гаврилов, Л. П. Распознавание речи: алгоритмы и методы : моногр. / Л. П. Гаврилов, А. А. Смирнов. – М. : Наука, 2020. – 280 с. – ISBN 978-5-02-039567-8.
- 8 Григорьев, С. В. Разработка мобильных приложений с использованием ARKit и ARCore : моногр. / С. В. Григорьев, К. А. Дмитриев. – М. : Инфра-Инженерия, 2022. – 312 с. – ISBN 978-5-9729-0678-9.
- 9 Датасет Mozilla Common Voice для обучения моделей распознавания речи [Электронный ресурс] // Mozilla. – Режим доступа : <https://commonvoice.mozilla.org/ru/>. – 14.03.2025.

- 10 Дроздов, А. А. Искусственный интеллект: от теории к практике : моногр. / А. А. Дроздов, И. С. Лебедев. – М. : Эксмо, 2021. – 288 с. – ISBN 978-5-04-112345-6.
- 11 Егоров, А. Н. Глубокое обучение: практическое руководство : моногр. / А. Н. Егоров, В. П. Тихонов. – М. : ДМК Пресс, 2020. – 368 с. – ISBN 978-5-97060-678-7.
- 12 Жуковский, В. И. Машинный перевод: современные подходы : моногр. / В. И. Жуковский, А. А. Козлов. – М. : Либроком, 2019. – 224 с. – ISBN 978-5-397-06789-0.
- 13 Захаров, И. В. Обработка звуковых сигналов: методы и алгоритмы : моногр. / И. В. Захаров, А. А. Семенов. – М. : Радио и связь, 2021. – 296 с. – ISBN 978-5-256-07890-1.
- 14 Иванов, Д. С. Разработка приложений дополненной реальности : моногр. / Д. С. Иванов, Е. А. Петрова. – СПб. : БХВ-Петербург, 2022. – 340 с. – ISBN 978-5-9775-7890-2.
- 15 Калинин, А. А. Машинное обучение в обработке естественного языка : моногр. / А. А. Калинин, В. В. Морозов. – М. : Физматлит, 2020. – 272 с. – ISBN 978-5-9221-1678-9.
- 16 Козлов, С. П. Глубокие нейронные сети: теория и практика : моногр. / С. П. Козлов, А. В. Николаев. – М. : Техносфера, 2021. – 384 с. – ISBN 978-5-94836-789-4.
- 17 Куликов, А. В. Распознавание речи: современные технологии : моногр. / А. В. Куликов, Д. А. Соколов. – М. : Наука, 2022. – 320 с. – ISBN 978-5-02-040123-4.
- 18 Лебедев, И. В. Машинное обучение для разработчиков : моногр. / И. В. Лебедев, А. А. Смирнов. – М. : Эксмо, 2021. – 304 с. – ISBN 978-5-04-112678-5.
- 19 Литвинов, А. А. Дополненная реальность в мобильных приложениях : моногр. / А. А. Литвинов, В. П. Федоров. – М. : Инфра-Инженерия, 2020. – 256 с. – ISBN 978-5-9729-0456-3.

- 20 Марков, А. В. Искусственный интеллект: основы и применение : моногр. / А. В. Марков, С. К. Петров. – М. : Лань, 2022. – 336 с. – ISBN 978-5-8114-7890-5.
- 21 Мельников, А. А. Глубокое обучение: практическое применение : моногр. / А. А. Мельников, В. В. Сидоров. – М. : ДМК Пресс, 2021. – 352 с. – ISBN 978-5-97060-890-3.
- 22 Метрики оценки качества машинного перевода [Электронный ресурс] // WMT 2022. – Режим доступа : <https://www.statmt.org/wmt22/metrics/index.html/>. – 14.03.2025.
- 23 Николаев, В. П. Машинный перевод: технологии и методы : моногр. / В. П. Николаев, А. А. Семенов. – М. : Физматлит, 2020. – 288 с. – ISBN 978-5-9221-1789-2.
- 24 Облачный перевод Google. Оценка качества перевода с AutoML [Электронный ресурс] // Google Cloud. – Режим доступа : <https://cloud.google.com/translate/docs/advanced/automl-evaluate/>. – 14.03.2025.
- 25 Огромные языковые модели в Яндекс переводчике [Электронный ресурс] // Habr. – Режим доступа : <https://habr.com/ru/companies/yandex/articles/884416/>. – 14.03.2025.
- 26 Орлов, А. В. Разработка приложений с использованием ARKit : моногр. / А. В. Орлов, С. К. Петров. – М. : БХВ-Петербург, 2021. – 312 с.
- 27 Оценка качества перевода: метрика BLEU [Электронный ресурс] // Habr. – Режим доступа : <https://habr.com/ru/articles/737950/>. – 14.03.2025.
- 28 Павлов, А. А. Машинное обучение: практическое руководство : моногр. / А. А. Павлов, В. В. Соколов. – М. : Эксмо, 2022. – 368 с.
- 29 Петров, А. В. Обработка естественного языка: практическое применение : моногр. / А. В. Петров, С. К. Иванов. – М. : Лань, 2021. – 304 с.
- 30 Романов, А. А. Глубокие нейронные сети: теория и практика : моногр. / А. А. Романов, В. В. Смирнов. – М. : Техносфера, 2020. – 352 с.
- 31 Сидоров, А. В. Машинное обучение: алгоритмы и методы : моногр. / А. В. Сидоров, В. П. Кузнецов. – М. : ДМК Пресс, 2021. – 336 с.

- 32 Смирнов, А. А. Распознавание речи: современные подходы : моногр. / А. А. Смирнов, В. В. Петров. – М. : Наука, 2022. – 320 с.
- 33 Создание собственной модели машинного перевода [Электронный ресурс] // Habr. – Режим доступа : <https://habr.com/ru/articles/689580/>. – 14.03.2025.
- 34 Сравнение моделей машинного обучения [Электронный ресурс] // Springer. – Режим доступа : <https://link.springer.com/article/10.1007/s10579-021-09537-5#Tab1/>. – 14.03.2025.
- 35 Сравнение различных сервисов машинного перевода [Электронный ресурс] // Habr. – Режим доступа : <https://habr.com/ru/articles/852810/>. – 14.03.2025.
- 36 Сравнение DeepL и Яндекс.Переводчика [Электронный ресурс] // Umanistica Digitale. – Режим доступа : <https://umanisticadigitale.unibo.it/article/view/12631/12797/>. – 14.03.2025.
- 37 Тихонов, В. П. Глубокое обучение: практическое руководство : моногр. / В. П. Тихонов, А. Н. Егоров. – М. : ДМК Пресс, 2020. – 368 с.
- 38 Точность перевода с использованием DeepL [Электронный ресурс] // ResearchGate. – Режим доступа : https://www.researchgate.net/publication/381958486_Accuracy_Analysis_of_DeepL_Breakthroughs_in_Machine_Translation_Technology/fulltext/6685ed852aa57f3b8269c3ff/Accuracy-Analysis-of-DeepL-Breakthroughs-in-Machine-Translation-Technology.pdf?origin=scientificContributions – 14.03.2025.
- 39 Федоров, А. В. Дополненная реальность: технологии и применение : моногр. / А. В. Федоров, В. П. Лебедев. – СПб. : Питер, 2019. – 180 с.
- 40 Харитонов, А. А. Машинное обучение: основы и применение : моногр. / А. А. Харитонов, В. В. Соколов. – М. : Техносфера, 2021. – 320 с.
- 41 Цветков, А. В. Обработка естественного языка: методы и алгоритмы : моногр. / А. В. Цветков, В. П. Иванов. – М. : Лань, 2020. – 256 с.
- 42 Чернов, А. А. Разработка приложений дополненной реальности: моногр. / А. А. Чернов, В. В. Петров. – СПб. : БХВ-Петербург, 2022. – 340 с.

- 43 Что такое BLEU Score? [Электронный ресурс] // Microsoft Learn. – Режим доступа : <https://learn.microsoft.com/en-us/azure/ai-services/translator/custom-translator/concepts/bleu-score/>. – 14.03.2025.
- 44 Широков, А. В. Машинное обучение: практическое руководство : моногр. / А. В. Широков, В. П. Козлов. – М. : Эксмо, 2021. – 352 с.
- 45 Яковлев, А. А. Глубокие нейронные сети: теория и практика : моногр. / А. А. Яковлев, В. В. Смирнов. – М. : Техносфера, 2020. – 352 с.
- 46 Яковлев, В. П. Машинное обучение: алгоритмы и методы : моногр. / В. П. Яковлев, А. А. Петров. – М. : ДМК Пресс, 2021. – 336 с.
- 47 Яковлев, С. В. Обработка звуковых сигналов: методы и алгоритмы : моногр. / С. В. Яковлев, А. А. Иванов. – М. : Радио и связь, 2021. – 296 с. –
- 48 Яковлев, В. В. Машинное обучение: основы и применение : моногр. / В. В. Яковлев, А. А. Соколов. – М. : Техносфера, 2021. – 320 с. –
- 49 Яковлев, А. В. Разработка приложений с использованием ARCore : моногр. / А. В. Яковлев, В. П. Петров. – М. : БХВ-Петербург, 2021. – 312 с.
- 50 Яковлев, В. А. Машинное обучение: практическое руководство : моногр. / В. А. Яковлев, А. А. Смирнов. – М. : Эксмо, 2022. – 368 с.
- 51 Яковлев, С. А. Обработка естественного языка: практическое применение : моногр. / С. А. Яковлев, В. В. Иванов. – М. : Лань, 2021. – 304 с.
- 52 Яковлев, А. П. Глубокие нейронные сети: теория и практика : моногр. / А. П. Яковлев, В. В. Соколов. – М. : Техносфера, 2020. – 352 с.