



Факультет гуманитарных наук

Фундаментальная и
прикладная лингвистика

Нижний Новгород

Создание корпуса устной речи для диагностических целей с использованием автоматических алгоритмов распознавания речи

Докладчик: Жилина Полина Павловна 21ФиПЛ-2

Научный руководитель: к. филол. н., старший научный сотрудник Центра языка и мозга,
Хоменко Анна Юрьевна

Соруководитель: приглашенный преподаватель, Бадасян Александра Арсеновна



Актуальность

- Устная речь – источник когнитивной и психоэмоциональной информации.
- Точная транскрипция – основа лингвистического и диагностического анализа.
- Автоматическое распознавание речи (Automatic Speech Recognition, ASR) позволяет масштабировать обработку звучащей речи.
- Анnotatedные корпуса – ключевой ресурс для анализа устной речи в том числе в диагностических и исследовательских целях.



Новизна

В отличие от большинства русскоязычных работ, ограничивающихся использованием различных версий модели Whisper для автоматического распознавания речи (Мамаев, 2023; Sherstnova и др., 2024), **в настоящем исследовании сравнивается эффективность трёх современных ASR-моделей — *whisper-large-v3-turbo*, *nemo-fastconformer-ru-rnnt*, *gigaam-v2-rnnt***, две из которых редко применяются в лингвистических исследованиях, но при этом демонстрируют высокую точность распознавания русской устной речи на различных наборах данных (Иступаков, 2025).



Объект:

устная речь, содержащая достоверную и недостоверную информацию.

Предмет:

- особенности устной речи, которые либо не поддаются фиксации средствами автоматического распознавания речи (ASR), либо воспроизводятся неверно, приводя к ошибкам в транскриптах.
- особенности дискурсивной разметки автоматически созданных транскриптов.

Цель работы:

создание корпуса устной речи для диагностических целей, содержащего как правдивые так и ложные высказывания, с применением современных алгоритмов автоматического распознавания речи



Задачи:

- проанализировать научную литературу по теме исследования;
- **получить и сравнить автоматические транскрипты с эталонными ручными расшифровками**, подготовленными для анализа ошибок распознавания;
- **классифицировать ошибки** с точки зрения их лингвистической и диагностической значимости;
- **выявить наиболее эффективный алгоритм распознавания речи** для создания последующих транскриптов в корпусе;
- **разработать протокол разметки транскриптов**, учитывая специфику диагностического корпуса;
- **сформировать структуру корпуса** и подготовить его к размещению в виде открытого репозитория.



Методы:

- **Автоматического создания транскриптов** с использованием ASR-моделей *whisper-large-v3-turbo*, *nemo-fastconformer-ru-rnnt* и *gigaam-v2-rnnt*.
- **Ручного создания транскриптов** для создания эталонных текстов.
- **Сравнительного анализа** для сопоставление автоматически созданных и ручных транскриптов, классификация и локализация ошибок.
- **Дискурсивной разметки** для разработки протокола аннотирования речевых данных в корпусе.



Материал исследования:

- **60 аудиофайлов (20 человек);**
- **Возрастная группа: от 17 до 67 лет;**
- **Общая продолжительность материала: 231 минута 37 секунд;**
- **Устные рассказы респондентов, собранные в три этапа:**
 - **Этап 1.** Ложный рассказ:
 - Респондент по заданному плану рассказывал о вымышленном событии, заведомо зная, что должен лгать; после монолога интервьюер задавал уточняющие вопросы.
 - **Этап 2.** Правдивый рассказ:
 - Респондент описывал реальное событие, также с опорой на план. Вопросы задавались после рассказа.
 - **Этап 3.** Свободный выбор:
 - Респондент сам решал, будет ли его рассказ правдивым или вымышленным. Интервьюер также задавал уточняющие вопросы.



Автоматические метрики оценки качества распознавания речи

WER (Word Error Rate) - показатель, оценивающий частоту ошибок на уровне слов.

CER (Character Error Rate) - показатель, оценивающий частоту ошибок на уровне символов.

WIP (Word Information Preserved) – показывает, насколько эффективно система сохраняет информацию из оригинального высказывания.

WIL (Word Information Lost) – измеряет долю утраченной информации в результате ошибок распознавания.

*Чем ниже значения метрик **WER**, **CER** и **WIL**, тем выше точность и качество распознавания.

Результаты

Оценка производилась на аудиоданных общей длительностью **71 минута 41 секунд** (30.95% от общего кол-ва записанного материала)

метрика (%) / ASR - модель	<i>nemo-fastconformer-ru-rnnt</i>	<i>whisper-large-v3-turbo</i>	<i>gigaam-v2-rnnt</i>
WER	11.09	16.46	6.18
CER	4.4	9.94	2.13
WIL	17.42	20.84	9.54
WIP	82.58	79.16	90.46

Таблица 1. Результаты оценки качества на незашумленном аудиоматериале

метрика (%) / ASR - модель	<i>nemo-fastconformer-ru-rnnt</i>	<i>whisper-large-v3-turbo</i>	<i>gigaam-v2-rnnt</i>
WER	22.48	24.77	13.18
CER	9.11	16.63	6.28
WIL	34.47	32.11	19.53
WIP	65.53	67.89	80.47

Таблица 2. Результаты метрик оценки качества на зашумленном аудиоматериале



Результаты (классификация ошибок)

- **Ошибки, не искажающие смысл**

- Затрагивают лишь формальные грамматические характеристики слова (например, род, число, падеж у существительных и прилагательных):

эталонный транскрипт гипотеза	отвезти другой моей подруге отвезти другой моей подруги
----------------------------------	--

- **Ошибки, искажающие смысл.** В результате появляется:

- полностью другая лексема(ы), не связанная с контекстом, но схожая по звуковому облику:

эталонный транскрипт гипотеза	мне дают бланк я заполняю этот бланк не дают бланк я заполняю этот банк
----------------------------------	--

- несуществующий звуковой аналог:

эталонный транскрипт гипотеза	не было толкучки никто на пятки не наступал не было толпучки никто на пятки не наступал
----------------------------------	--

Результаты

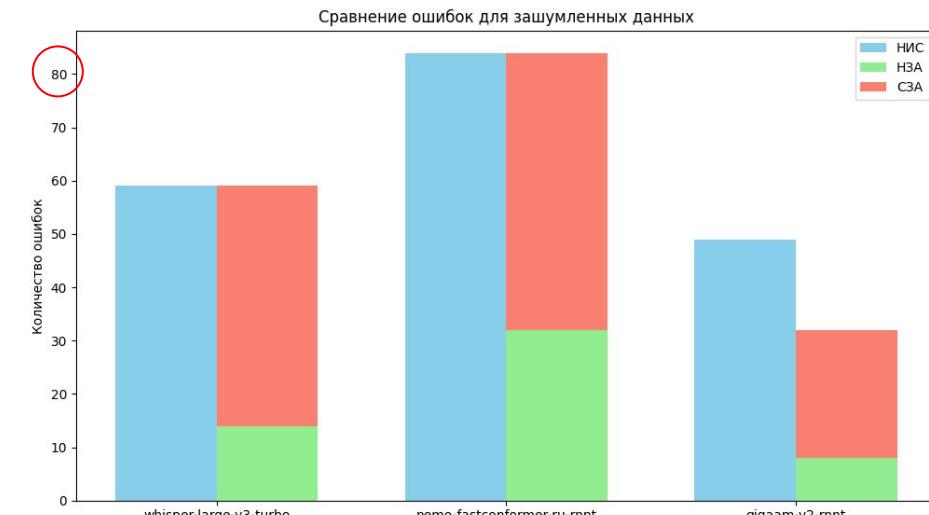
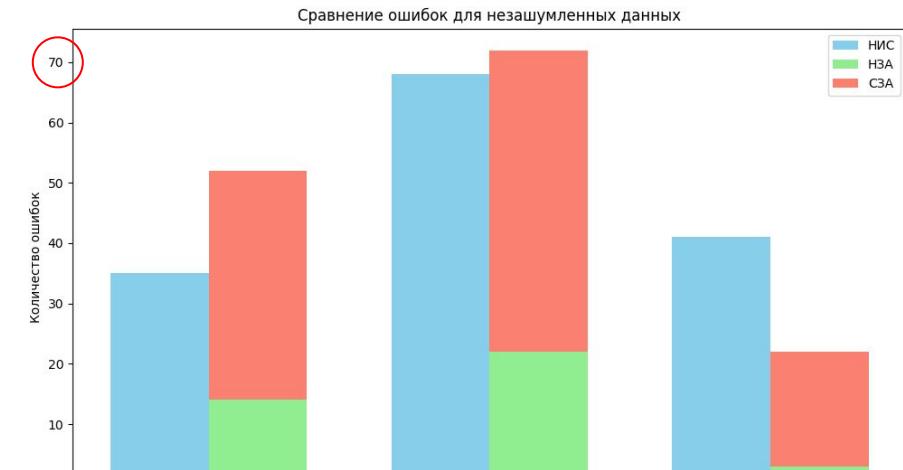
Для каждой модели было выявлено общее количество ошибок:

- на незашумленных данных:
 - *whisper-large-v3-turbo* – 87 ошибок
 - *nemo-fastconformer-ru-rnnt* – 140 ошибок
 - *gigaam-v2-rnnt* – 62 ошибки

Общее количество токенов: 4812

- на зашумленных данных:
 - *whisper-large-v3-turbo* – 123 ошибки
 - *nemo-fastconformer-ru-rnnt* – 189 ошибок
 - *gigaam-v2-rnnt* – 81 ошибки

Общее количество токенов: 4167



НИС — ошибки, не искажающие смысл
НЗА — замена на несуществующий звуковой аналог
СЗА — замена на существующий звуковой аналог



Результаты (ошибки пропусков)

Модель распознавания речи/вид ошибки	Служебные слова (предлоги, союзы, частицы)	Знаменательные слова	Целые предложения/отде- льные клаузы	Хезитационные паузы	Самопереби- вания
<i>whisper-large-v3-turbo</i>	✓	✓	✓	✓	✓
<i>nemo-fastconformer-ru- rnnt</i>	✓	✓ (только личные местоимения)	✗	✓	✓
<i>gigaam-v2-rnnt</i>	✓	✓ (только личные местоимения)	✗	✓	✓

Таблица 3. Распределение видов пропусков по моделям автоматического распознавания речи



Протокол разметки

Цель: разработка унифицированной системы аннотаций, обеспечивающей релевантность корпуса для задач диагностики правдивости/ложности устной речи.

Основные принципы:

- Разделение речевого потока на элементарные дискурсивные единицы (ЭДЕ).
- Фиксация речевых сбоев (паузы, повторы, фальстарты, самокоррекции) как индикаторов когнитивной нагрузки и коммуникативной неуверенности.

Теоретическая база:

- Исследования, выявляющие взаимосвязь речевых сбоев и восприятия лжи (Chen et al., 2020; Loy, Rohde, Corley, 2017; Solà-Sales и др., 2023; Loy, Rohde, Corley, 2018).
- Работа «Самоисправления говорящего и другие типы речевых сбоев как объект аннотирования в корпусах устной речи» (Подлесская В. И., Кибрик А. А., 2007) акцентирующая внимание на значимости системной фиксации речевых сбоев для изучения когнитивных и прагматических аспектов устного дискурса, подчеркивая их роль как ключевого объекта аннотирования в корпусах устной речи.

Практическая реализация:

- Протокол основан на системе разметки проекта «Рассказы о сновидениях...» (Кибрик А. и др., 2009), адаптированной для автоматического анализа (регулярные выражения, подсчет частот).

Значимость: создание инструмента, сочетающего традиции корпусной лингвистики и требования к машинной обработке, для поддержки последующих исследований в области диагностики речевой лжи.



Протокол разметки

- **Произведена замена 7 существующих обозначений** (незаполненные и заполненные паузы, пограничные паузы, обозначение интонации многоточия, отображение удлинения в произнесение слов, специальная фиксация пересекающихся реплик, обозначение неразборчивых звуковых отрезков);
- **Введено 3 новых обозначения** ($|E|$ – знак границы неполноценной ЭДЕ, $|S|$ – знак границы незавершенного предложения, $|ES|$ – знак границы ЭДЕ совмещенный с границей предложения);
- **Произведена замена существующих обозначений в связи с введением новых символов** (фиксации сильного фальстарта, обозначение сплита (разрыва внутри ЭДЕ), бозначение односторонней и обычной парентезы).

Пример отображения сплита:

Там сидели мои друзья $|E|$
дво-о-е, ...(0.3)
или тро-о-е,
и брат мой старший был.

Пример отображения парентезы:

Я вчера прихожу домой $|E|$
(А было темно-о уже.)
слышу,
дверь хлопает, ...(0.3)
и кто-то мне из темноты:
«Вы не подскажете?,
где тут магазин?»

С подробной версией протокола вы можете ознакомиться, перейдя по QR-коду:





Code Blame 1.92 MB

Raw

README

View raw

Truth-Or-Lie-Speech-Corpora

Аудиофайл	Транскрипт	Разметка
Ж18 (1) 3.mp3	ссылка	Ж18 (1) 3_2.txt
Ж18 (1) врёт.mp3	ссылка	Ж18 (1) врёт.mp3
Ж18 (1) правда.mp3	ссылка	Ж18 (1) правда.txt
Ж18 (2) 3.mp3	ссылка	Ж18 (2) 3.txt
Ж18 (2) врёт.mp3	ссылка	Ж18(2) врет.txt
M19 (1) говорит правду.mp3	ссылка	M19(1)врет.txt
M19 (2) говорит правду.mp3	ссылка	M19_3.txt
M19 (2) 3.mp3	ссылка	M19(2)3.txt
M18(1) врёт.mp3	ссылка	M18(1)_врёт.txt
M18(2) правда.mp3	ссылка	M18(2)_правда.txt

Code Blame 32 lines (31 loc) · 2.73 KB

Raw

```
1 Время начала - ЧЧ:ММ:СС.МС Время окончания - ЧЧ:ММ:СС.МС Длительность - ЧЧ:ММ:СС.МС Рассказчик
2 00:00:00.080 00:00:01.690 00:00:01.610 Меня зовут Алексеева Анна,
3 00:00:02.320 00:00:04.500 00:00:02.180 я ходила на концерт со своими друзьями |E|
4 00:00:04.510 00:00:06.340 00:00:01.830 на концерт Рамиля. ... (0.4)
5 00:00:06.340 00:00:09.410 00:00:03.070 Инициатором концерта была я. ... (0.5)
6 00:00:09.412 00:00:15.451 00:00:06.039 А(0.3) так... (0.5) мне очень понравились эмоции от этого концерта,
7 00:00:15.451 00:00:18.686 00:00:03.235 а(0.2) времепровождение,
8 00:00:18.706 00:00:19.608 00:00:00.902 а(0.1) очень круто. |S|
9 00:00:24.784 00:00:27.529 00:00:02.745 Я бы порекомендовала своим друзьям сходить на такой концерт,
10 00:00:27.529 00:00:32.588 00:00:05.059 а(0.2) чтобы отвлечься ... (0.3) от своих проблем,
11 00:00:32.608 00:00:35.824 00:00:03.216 а(0.2) чтобы провести круто время,
12 00:00:35.843 00:00:36.882 00:00:01.039 ну и всё.
```

Code Blame 4 lines (2 loc) · 2.92 KB

Raw

```
1 Я Алексеева Анна. Аа, Я н= совсем... ну вот [наверное] на этой неделе, аа, лазила в инстаграме и наткнулась на шоу-рум. Мне там очень сильно
2
3
4 Угу. Аа, какого цвета было платье? – Черное. – Черное. Ам, так, второй вопрос. Эм, в каком районе Челябинска, да, в Челябинске же это про
```



Итоги

- Модель *gigaam-v2-rnnt* выбрана для финальной работы с корпусом.
- Современные ASR-системы не фиксируют паралингвистические элементы (паузы, фальстарты, самоперебивы) и требуют дообучения на специализированных данных.
- Все модели допускают как ошибки, искажающие смысл высказываний, так и ошибки, затрагивающие лишь грамматические категории, однако их частотность и выраженность различаются.
- Разработан протокол аннотирования, основанный на существующих принципах разметки устных корпусов, фиксирующий речевые сбои как потенциальные маркеры лжи и адаптированный для автоматического анализа.
- Корпус создан как открытый ресурс для дальнейшего расширения и исследований в области диагностики правдивости/ложности устной речи.



Факультет гуманитарных
наук

Фундаментальная и
прикладная лингвистика

Нижний Новгород

17

Ограничения

Список источников

1. Мамаев И. Д. АВТОМАТИЧЕСКАЯ РАСШИФРОВКА ЗАПИСЕЙ УСТНОЙ РЕЧИ: ТЕСТИРОВАНИЕ ПРОГРАММЫ WHISPER1. – 2023.
2. Sherstnova T. et al. Bridging gaps in Russian language processing: AI and everyday conversations //2024 35th Conference of Open Innovations Association (FRUCT). – IEEE, 2024. – С. 665-674.
3. Подлесская В. И., Кибрик А. А. Самоисправления говорящего и другие типы речевых сбоев как объект аннотирования в корпусах устной речи //Научно-техническая информация. Серия. – 2007. – Т. 2. – С. 2-23.
4. Chen X. et al. Acoustic-prosodic and lexical cues to deception and trust: deciphering how people detect lies //Transactions of the Association for Computational Linguistics. – 2020. – Т. 8. – С. 199-214.
5. Loy J. E., Rohde H., Corley M. Effects of disfluency in online interpretation of deception //Cognitive Science. – 2017. – Т. 41. – С. 1434-1456.
6. Loy J. E., Rohde H., Corley M. Cues to lying may be deceptive: Speaker and listener behaviour in an interactive game of deception //Journal of Cognition. – 2018. – Т. 1. – №. 1. – С. 42.
7. Кибрик А. и др. (ред.). Рассказы о сновидениях: Корпусное исследование устного русского дискурса. – Litres, 2022.
8. Solà-Sales S. et al. Analysing deception in witness memory through linguistic styles in spontaneous language //Brain sciences. – 2023. – Т. 13. – №. 2. – С. 317.
9. Wieczorkowska A. Methodology for Obtaining High-Quality Speech Corpora //Applied Sciences. – 2025. – Т. 15. – №. 4. – С. 1848.

Результаты

Модель распознавания речи/вид ошибки	Замены, не влияющие на смысл (%)	Замены, искажающие смысл (%)	Замена на несуществующий звуковой аналог (%)	Замена на существующую лексему, не связанную с контекстом, но схожую по звуковому облику (%)
<i>whisper-large-v3-turbo</i>	52%	48%	24%	76%
<i>nemo-fastconformer-ru-rnnt</i>	56%	44%	38%	62%
<i>gigaam-v2-rnnt</i>	40%	60%	25%	75%

Таблица 4. Распределение ошибок замены в транскриптах моделей автоматического распознавания речи (в условиях фоновых шумов)



Результаты

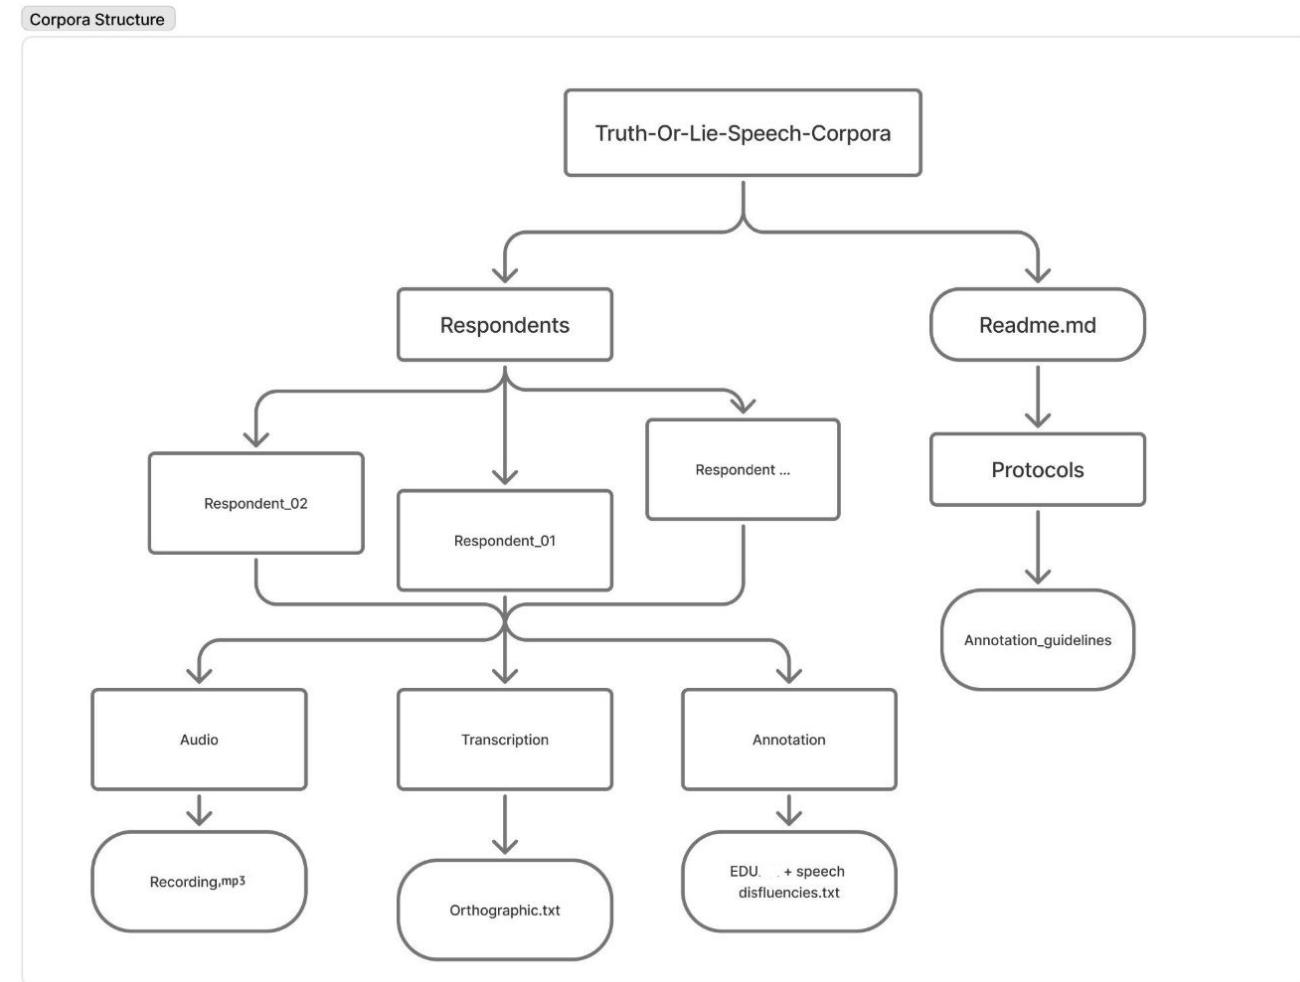
Для каждой модели было выявлено общее количество ошибок (на незашумленных данных):

- *whisper-large-v3-turbo* – 87 ошибок
- *nemo-fastconformer-ru-rnnt* – 140 ошибок
- *gigaam-v2-rnnt* – 62 ошибки

Для зашумленных данных:

Подмножество распределения ошибок, не влияющие на смысл лексемы (%)	Количество выделенных классов: замены, искажающие смысл лексемы (%)	Замена на несуществующий звуковой аналог (%)	Замена на существующую лексему, не связанную с контекстом, но схожую по звуковому облику (%)
<i>whisper-large-v3-turbo</i>	39%	61%	28%
<i>nemo-fastconformer-ru-rnnt</i>	49%	51%	31%
<i>gigaam-v2-rnnt</i>	67%	77%	13%

Создание архитектуры корпуса



Результаты

Результаты автоматической оценки качества транскриптов, созданных тремя ASR-алгоритмами в нормальных условиях (без зашумлений):

метрика (%) / ASR - модель	<i>nemo-fastconformer-ru-rnnt</i>	<i>openai/whisper-large-v3-turbo</i>	<i>gigaam-v2-rnnt</i>
WER (Word Error Rate)	11.09	16.46	6.18
CER (Character Error Rat)	4.4	9.94	2.13
WIL (Word Information Lost)	17.42	20.84	9.54
WIP (Word Information Preserved)	82.58	79.16	90.46

Таблица 1. Сравнение метрик качества автоматического распознавания речи для трёх моделей ASR в условиях без зашумлений

Оценка производилась на аудиозаписях общей длительностью 31 минуту 21 секунду (15% от общего кол-ва незашумленного материала)



Результаты

Результаты автоматической оценки качества транскриптов, созданных тремя ASR-алгоритмами (зашумлённые условия):

метрика (%) / ASR - модель	<i>nemo-fastconformer-ru-rnnt</i>	<i>openai/whisper-large-v3-turbo</i>	<i>gigaam-v2-rnnt</i>
WER (Word Error Rate)	22.48	24.77	13.18
CER (Character Error Rat)	9.11	16.63	6.28
WIL (Word Information Lost)	34.47	32.11	19.53
WIP (Word Information Preserved)	65.53	67.89	80.47

Таблица 2. Сравнение метрик качества автоматического распознавания речи для трёх моделей ASR в условиях с зашумлениями

Оценка проводилась на аудиозаписях из 6 аудиофайлов, в которых общая длительность монологической речи составила 24 минуты 16 секунд. Эта длительность соответствует всей монологической зашумленной речи, представленной в данном наборе данных (10.48% от общего материала).



Промежуточные итоги

- Модель ***gigaam-v2-rnnt*** продемонстрировала лучшие результаты среди протестированных систем.
- **Автоматическая транскрипция** рассматривается как **предварительный этап** подготовки итоговых транскриптов корпуса.
- Наиболее обоснованным на текущем этапе развития технологий остаётся **гибридный подход** (assisted transcription) (Bazillon, Esteve, Luzzati, 2004), сочетающий скорость автоматического распознавания с точностью и глубиной ручной корректировки.



Методы:

- **ASR:** автоматическая транскрипция с использованием моделей *whisper-large-v3-turbo*, *nemo-fastconformer-ru-rnnt* и *gigaam-v2-rnnt*.
- **Ручное создание транскриптов:** создание эталонных текстов для последующего сравнения с автоматическими транскриптами.
- **Сравнительный анализ:** сопоставление транскриптов, классификация и локализация ошибок.
- **Дискурсивная разметка:** разработка протокола аннотирования и структуры корпуса.