empenoso
23 сен в 05:24

«Просто используй Docker» — мой путь от Whisper к WhisperX

Простой 6 мин 11K

Open source*, Настройка Linux*, Python*, Умный дом

Кейс

Несколько недель назад я опубликовал статью о том, как превратить обычный диктофон в инструмент для расшифровки речи с помощью OpenAI Whisper. Идея была создать бесплатную и приватную систему ИИ диктофона, которая избавляет от необходимости переслушивать аудиозаписи лекций или выступлений. Тогда статья нашла своего читателя, собрав 140 закладок.

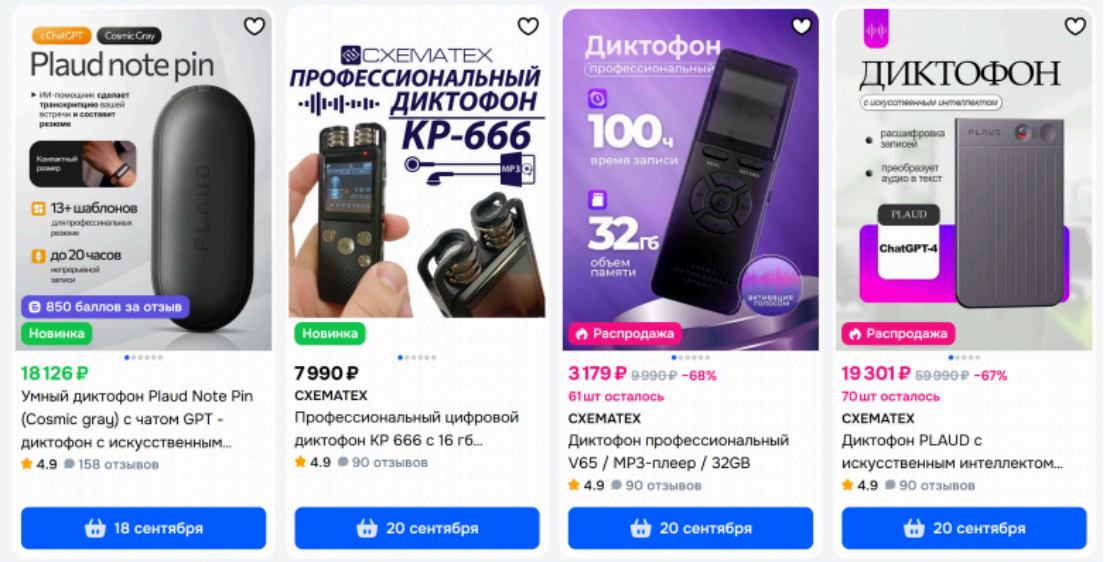

ИИ и обычные диктофоны

В процессе настройки я боролся с несовместимостью библиотек, подбирал нужные версии драйверов и вручную собирал рабочее окружение. В комментариях мне справедливо заметили: «Вместо всей этой возни можно было найти готовый Docker-контейнер и поднять всё одной командой». Звучало логично, и я с энтузиазмом принял этот совет. *Я ведь верю людям в интернете.*

Новая идея — не просто расшифровывать речь, а разделять её по голосам — как на совещании или встрече. Это называется диаризацией, и для неё существует продвинутая версия — WhisperX. Цель была проста — получить на выходе не сплошное полотно текста, а готовый протокол встречи, где понятно, кто и что сказал. Казалось, с Docker это будет легко.

Но я заблуждался. Путь «в одну команду» оказался полон сюрпризов — всё сыпалось одно за другим: то скрипт не видел мои файлы, то не мог получить к ним доступ, то просто зависал без объяснения причин. Внутри этой «волшебной упаковки» царил хаос, и мне приходилось разбираться, почему она не хочет работать.

Но когда я всё починил и заставил систему работать, результат превзошёл мои ожидания.

> Это был настолько лучший результат, что я смог передать его большой языковой модели (LLM) и получить глубокий анализ одной очень важной для меня личной ситуации — под таким углом, о котором я сам бы никогда не задумался.

Именно в этот момент мой скепсис в отношении «умных ИИ-диктофонов», которые я критиковал в первой статье, сильно пошатнулся. Скорее всего их сила не в тотальной записи, а в возможности превращать хаос в структурированные данные, готовые для анализа.

В этой статье я хочу поделиться своим опытом прохождения этого квеста, показать, как обойти все скрытые сложности, и дать вам готовые инструкции, чтобы вы тоже могли превращать свои записи в осмысленные диалоги.

Весь код выложен на Гитхаб.

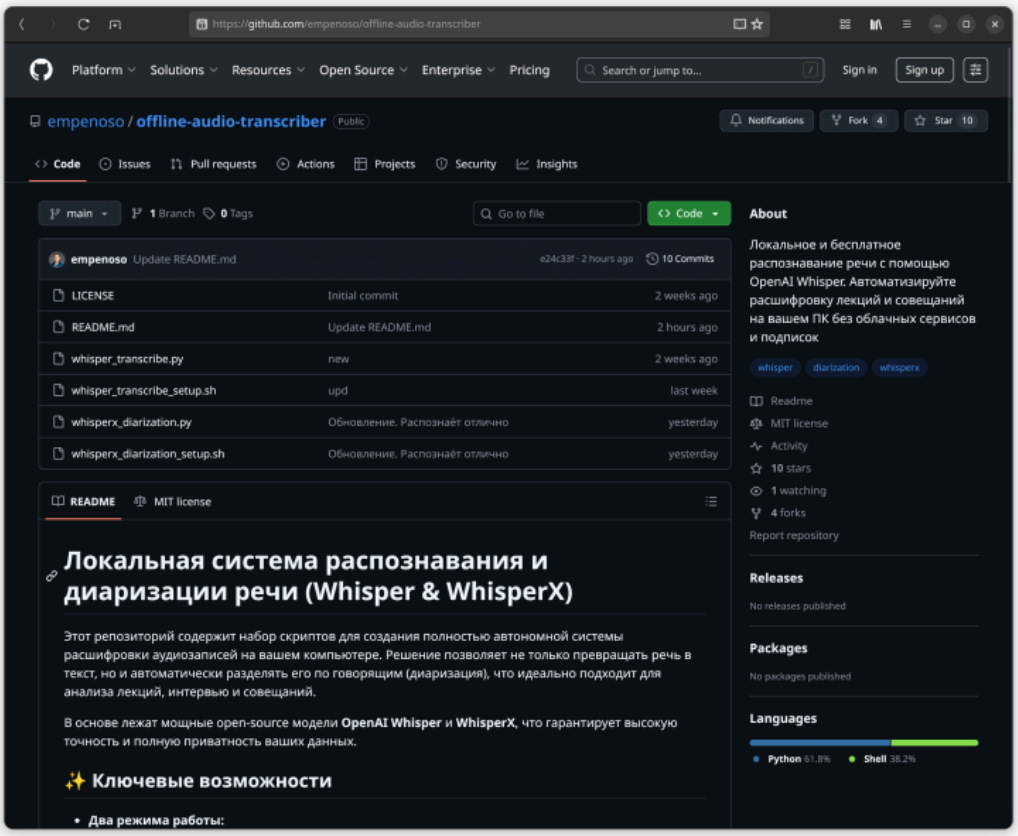

Код на Гитхабе

Docker как панацея и почему Linux

В комментариях меня критиковали за то, что я опять написал статью про Linux. Да, у меня на домашнем компьютере стоит Ubuntu в режиме двойной загрузки — и многим непонятно, почему я не сделал всё под Windows. Ответ прост: для задач с нейросетями Linux даёт меньше неожиданностей и больше контроля. Драйверы, контейнеры, права доступа — под Linux их проще исследовать и чинить, особенно когда начинаешь ковырять CUDA и системные зависимости.

Для выбора загрузки какую ОС использовать выбрал rEFInd Boot Manager

Ещё меня критиковали за RTX 5060 Ti 16GB — мол, не у всех такие видеокарты. Согласен, это не смартфон в кармане. Но для работы с большими моделями и диаризацией нужна мощь GPU: я использую её как инструмент. К тому же подходы, которые я описываю, работают и на более скромных конфигурациях — просто медленнее.

А теперь начнём с самого начала — что такое Docker простыми словами? Представьте, что вместо того, чтобы настраивать компьютер под каждую программу, вы берёте готовую «коробку» и в ней уже есть всё: нужные версии Python, библиотеки, утилиты. Эта «коробка» запускается одинаково на любой машине — как виртуальная мини-кухня.

То есть мой план действий был такой:

1. Установить Docker.
2. Скачать готовый образ с WhisperX.
3. Запустить одну команду и получить готовый протокол встречи.

Так что могло пойти не так?

Первое столкновение с реальностью

Уже на первом шаге начались сюрпризы:

Секретный токен, который не дошёл до адресата

Чтобы запустить диаризацию, WhisperX использует модели от pyannote, а они требуют авторизации через токен Hugging Face. Я передал его как переменную окружения Docker (`-e` ера ожидала одель упорно

Война за права доступа

Следующая засада — `PermissionError` при попытке записи в системные папки `/.cache`. Контейнер как гость в доме: ему разрешили пользоваться кухонным столом, а он пошёл сверлить стены в гостиной. Разумеется, система его остановила. Решение оказалось простым - создать отдельную «полку» для кеша (`~/.whisperx`) и явно указать путь.

Загадочное зависание

Запускаешь скрипт — и тишина. Ни ошибок, ни логов, будто процесс замёрз. На деле работа шла, просто механизм вывода в контейнере «затыкался». Решение — добавить индикатор прогресса.

Так что Docker — не магия, а всего лишь ещё один инструмент, который тоже нужно приручить.

Решение: два скрипта

Я написал две утилиты — один раз подготовить систему, второй — управлять обработкой. Это простая, надёжная пара: установщик устраняет системные «подводные камни», оркестратор — закрывает все проблемы запуска (HF-token, кэш, права, прогресс).

Шаг 1. Фундамент: `whisperx_diarization_setup.sh`

Назначение: однократно подготовить Ubuntu — поста вить Docker, NVIDIA toolkit, скачать образ

- проверяет дистрибутив и наличие GPU (`nvidia-smi`);
- устанавливает Docker и добавляет пользователя в группу docker;
- ставит NVIDIA Container Toolkit и настраивает runtime;
- подтягивает образ `ghcr.io/jim60105/whisperx:latest` ;
- создаёт `./audio` , `./results` и `~/whisperx` , выставляет права и генерирует `config.env` .

Пример:

```
# создаём директории и конфиг
mkdir -p ./audio ./results "$HOME/whisperx"
chmod -R 777 ./audio ./results "$HOME/whisperx"
cat > ./config.env <<'EOF'
HF_TOKEN=your_token_here
WHISPER_MODEL=large-v3
DEVICE=cuda
...
EOF
# загрузка образа
sudo docker pull ghcr.io/jim60105/whisperx:latest
```

Шаг 2. Пульт управления: whisperx_diarization.py

Роль: оркестратор — перебирает файлы, формирует корректную команду `docker run` и решает описанные проблемы. Как он их решает:

- HF_TOKEN передаётся и как `-e HF_TOKEN=...` , и в аргументах `--hf_token` при запуске whisperx;
- глобальная папка кеша `~/whisperx` монтируется в контейнер и назначается `HOME=/models` , `XDG_CACHE_HOME=/models/.cache` - проблем с `PermissionError` нет;
- прогресс-бар: чтение stderr контейнера и человеко-понятные статусы (VAD → транскрибация → выравнивание → диаризация);
- проверка готовности: `--check` тестирует Docker, образ и права записи.

Пример:

```
# про��ерка системы
python3 whisperx_diarization.py --check
# обработать всю папку
python3 whisperx_diarization.py
```

Подробная инструкция и актуальные скрипты - в репозитории:
👉 **https://github.com/empenoso/offline-audio-transcriber**

Когда все технические баталии были позади, я наконец смог оценить, стоила ли игра свеч. Результат был отличный.

В первой статье обычный Whisper выдавал сплошное текстовое полотно. Информативно, но безжизненно. Вы не знали, где заканчивается мысль одного человека и начинается реплика другого.

Было (обычный Whisper):

> ...да, я согласен с этим подходом но нужно учесть риски которые мы не обсудили например финансовую сторону вопроса и как это повлияет на сроки я думаю нам стоит вернуться к этому на следующей неделе...

Стало (WhisperX с диаризацией):

> [00:01:15.520 --> 00:01:19.880] SPEAKER_01: Да, я согласен с этим подходом, но нужно учесть риски, которые мы не обсудили.
> [00:01:20.100 --> 00:01:22.740] SPEAKER_02: Например, финансовую сторону вопроса и как это повлияет на сроки?
> [00:01:23.020 --> 00:01:25.900] SPEAKER_01: Именно. Я думаю, нам стоит вернуться к этому на следующей неделе.

WhisperX с диаризацией превращает этот монолит в сценарий пьесы. Каждый спикер получает свой идентификатор, а его реплики — точные временные метки. Разница колоссальная. Теперь это не просто расшифровка, а полноценный протокол.

Мой личный кейс

Но настоящая магия началась, когда я решил пойти дальше. Я взял расшифровку одного личного разговора, сохранённую в таком структурированном виде, и загрузил её в нейросеть Gemini 2.5 Pro с простым запросом: «Действуй как аналитик. Проанализируй этот диалог».

Именно из-за структуры Gemini смогла отследить, кто инициировал темы, кто чаще соглашался или перебивал, как менялась тональность и динамика беседы. В итоге я получил анализ скрытых паттернов в общении, о которых сам никогда бы не задумался. Это был взгляд на ситуацию с абсолютно неожиданной стороны, который помог мне лучше понять и себя, и собеседника.

Даже бесплатное приложение в телефоне может служить источником

Я понял, что их главная ценность «ИИ-диктофонов» — не в способности записывать каждый ваш шаг, а в умении превращать хаос человеческого общения в структурированные, машиночитаемые данные. Это открывает возможности: от создания кратких сводок по итогам встреч до глубокого анализа коммуникаций, который раньше был невозможен.

Заключение

В итоге путь от «просто используй Docker» к рабочей связке WhisperX показал очевидную вещь: контейнеры — удобный инструмент, но не магия.

Подготовка системы и правильная оркестровка запуска — это то, что превращает хаос в рабочий процесс. Если вы готовы потерпеть небольшие сложности ради удобства в дальнейшем — результат оправдает усилия: структурированные протоколы и возможность глубокого анализа бесед.

Автор: Михаил Шардин
🔗 Моя онлайн-визитка
📢 Telegram «Умный Дом Инвестора»

23 сентября 2025

Теги: диктофон, whisper, whisperx, rtx 5060, cuda, расшифровка аудио

Хабы: Open source, Настройка Linux, Python, Умный дом

Автоматизация / Данные / Финансы / Умные дома

Подписаться

Сайт Сайт GitHub

Комментарии 30

Публикации

ЛУЧШИЕ ЗА СУТКИ ПОХОЖИЕ

DRoman0v
20 часов назад

Воскресная барахолка под Валенсией: винтажная аудиотехника, ноутбуки и много чего ещё

7 мин 3.2K

+45 4 2

interpres
14 часов назад

Простой 7 мин 6.3K

Обзор Перевод

+40 43 13

alex0x08
20 часов назад

WiFi, который не ловил

Простой 4 мин 5.8K

Туториал

+37 41 26

IgorAnokhin
17 часов назад

Асинхронность vs. многопоточность: что выживет в эпоху No GIL?

14 мин 4.8K

Мнение

+34 56 27

RationalAnswer
22 часа назад

Шатдаун правительства США, а также Грокипедия от Илона Маска

8 мин 6.6K

Дайджест

+31 10 7

Erwinmal
18 часов назад

Pasta e basta! Как паста и макароны стали национальным блюдом Италии и покорили Россию и США? Часть 3

Простой 14 мин 1.7K

Ретроспектива

+27 14 0

dalerank
10 часов назад

Сам себе breakpoint

Простой 15 мин 2.1K

+25 26 9

adushein

10 мин 700

+21 4 0

nikgerasimenko
19 часов назад

Kandinsky Image научился генерировать изображения с надписями на русском

Простой 3 мин 2.2K

Обзор

+21 8 2

PatientZero
16 часов назад

У меня нет рта, но я должен выводить эмодзи морского конька

Средний 9 мин 2.1K

Обзор Перевод

+20 7 15

110+ докладов, история об IT-факапах и экскурсия в замок Шаакен: что ждёт айтишников в Светлогорске

Турбо

Показать еще

ИСТОРИИ

10 признаков, что вы работаете не там

На мороз!

Прогулка по IT Elements

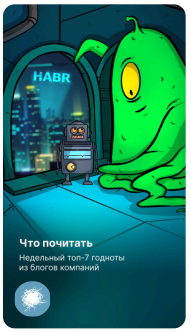

Годнота из блогов компаний

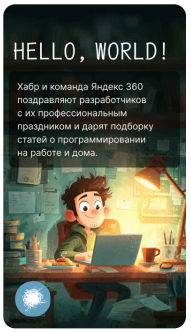

С Днём программиста!

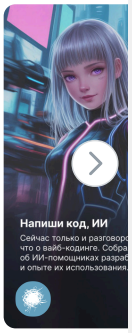

Made in AI

СРЕДНЯЯ ЗАРПЛАТА В IT

213 176 ₽/мес.

ерьте «в рынке»

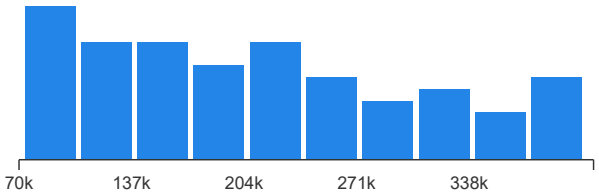

Проверить свою зарплату

МИНУТОЧКУ ВНИМАНИЯ

Взорвите рынок в безумной игре ко Дню программиста

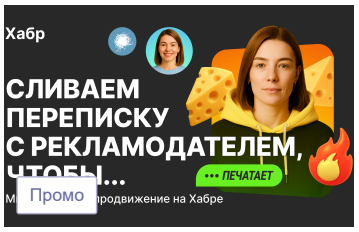

Как продвигаться на Хабре, если вы — не IT-бренд

Псст! Data-специалисты, расскажите о карьерных болях

БЛИЖАЙШИЕ СОБЫТИЯ

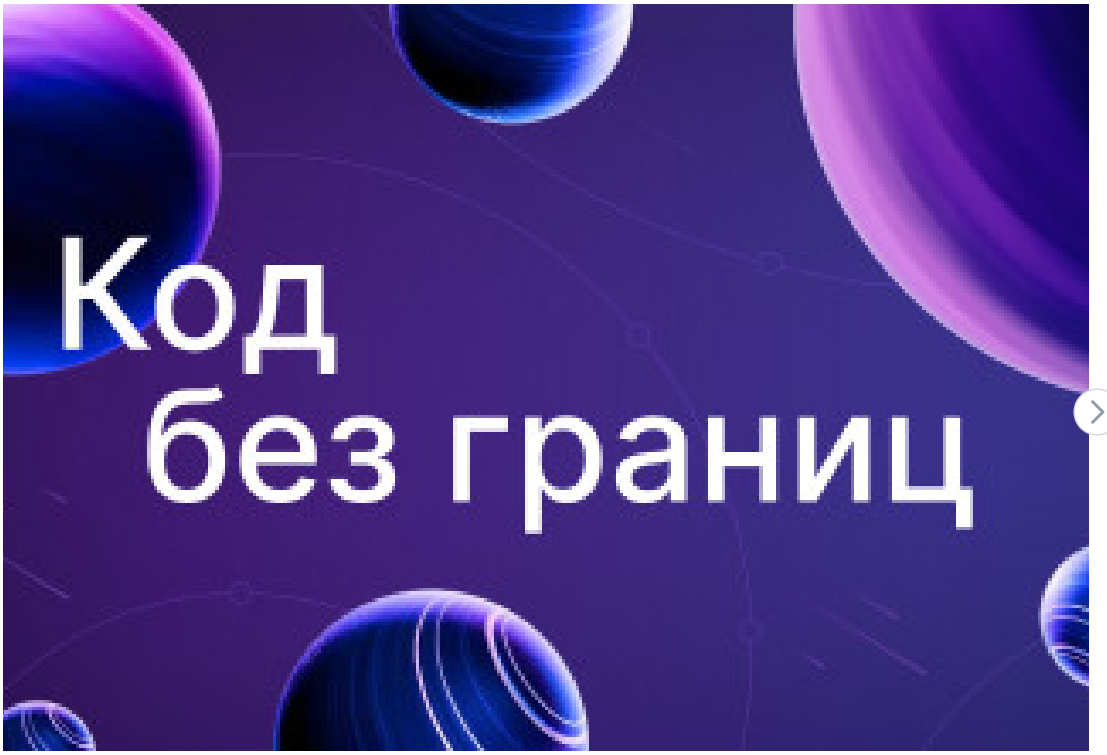

3 сентября – 31 октября

Программа грантов для развития open source проектов «Код без границ»

Онлайн

Разработка

Хабр

Настройка языка

Техническая поддержка