



# Сбор и разметка данных для машинного обучения

Евгения Суходольская, Data evangelist, Toloka

# Какие технологии зависят от данных?



Поиск



Беспилотник



Карты



Музыка



Голосовой помощник



E-commerce



Навигация



Фильмы



Облака



Реклама



Такси



Доставка



Перевод



Новости

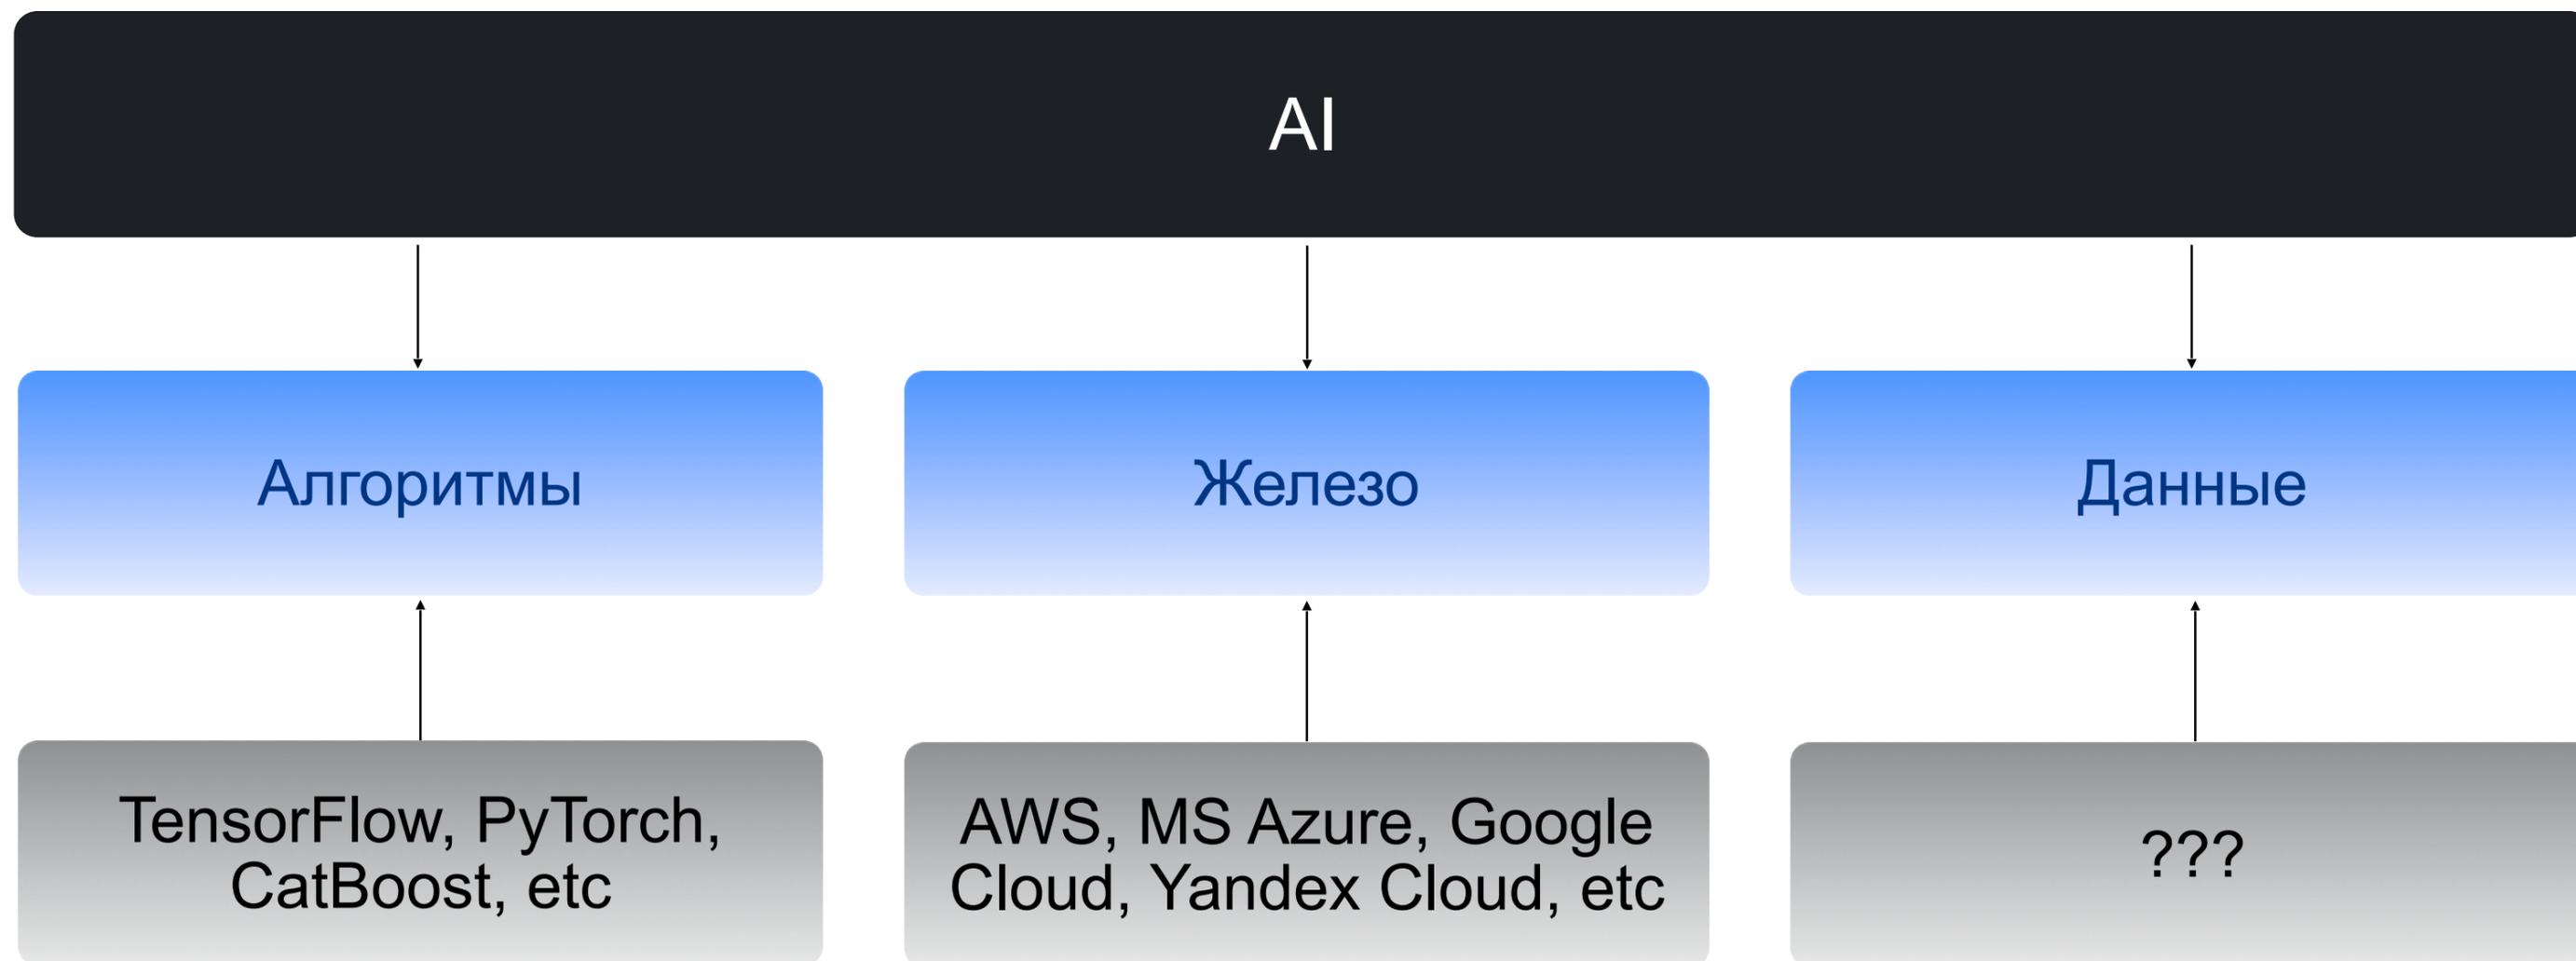


Почта



Здоровье

# Три “столпа”



# Три “столпа”: революция

AI

Алгоритмы

Железо

Данные

Привычный фокус

Потенциал  
роста

**Можно ли  
использовать готовые  
датасеты?**

# Откуда берутся данные?

## **Kaggle:**

→ Тебе выдали датасет - соревнование моделей

## **Реальность:**

→ Соревнуются целые конвейеры ML производства

# Пример 1: Перевод с ТОКСИЧНОГО

| Original  | Paraphrase   |
|---|--|
|   | <b>Reddit</b>  |
| this is scaring the shit out of me.   | This is really scaring me.                                       |
| this is a joke , are you all fucking retards?                                       | This is a joke, are you all crazy?                               |
| everybody is such a fucking pussy.  | Everybody is acting cowardly.                                    |
| did you think i was going to sit back and let some imbecile spew hatred towards me? | Did you think I was going to let an unreasonable person hate me? |
| calm the fuck down, cnn.  | Please calm your nerves, CNN.                                    |
| why is the scale of that graph so fucked up?  | Why is the scale of that graph not placed rightly.               |

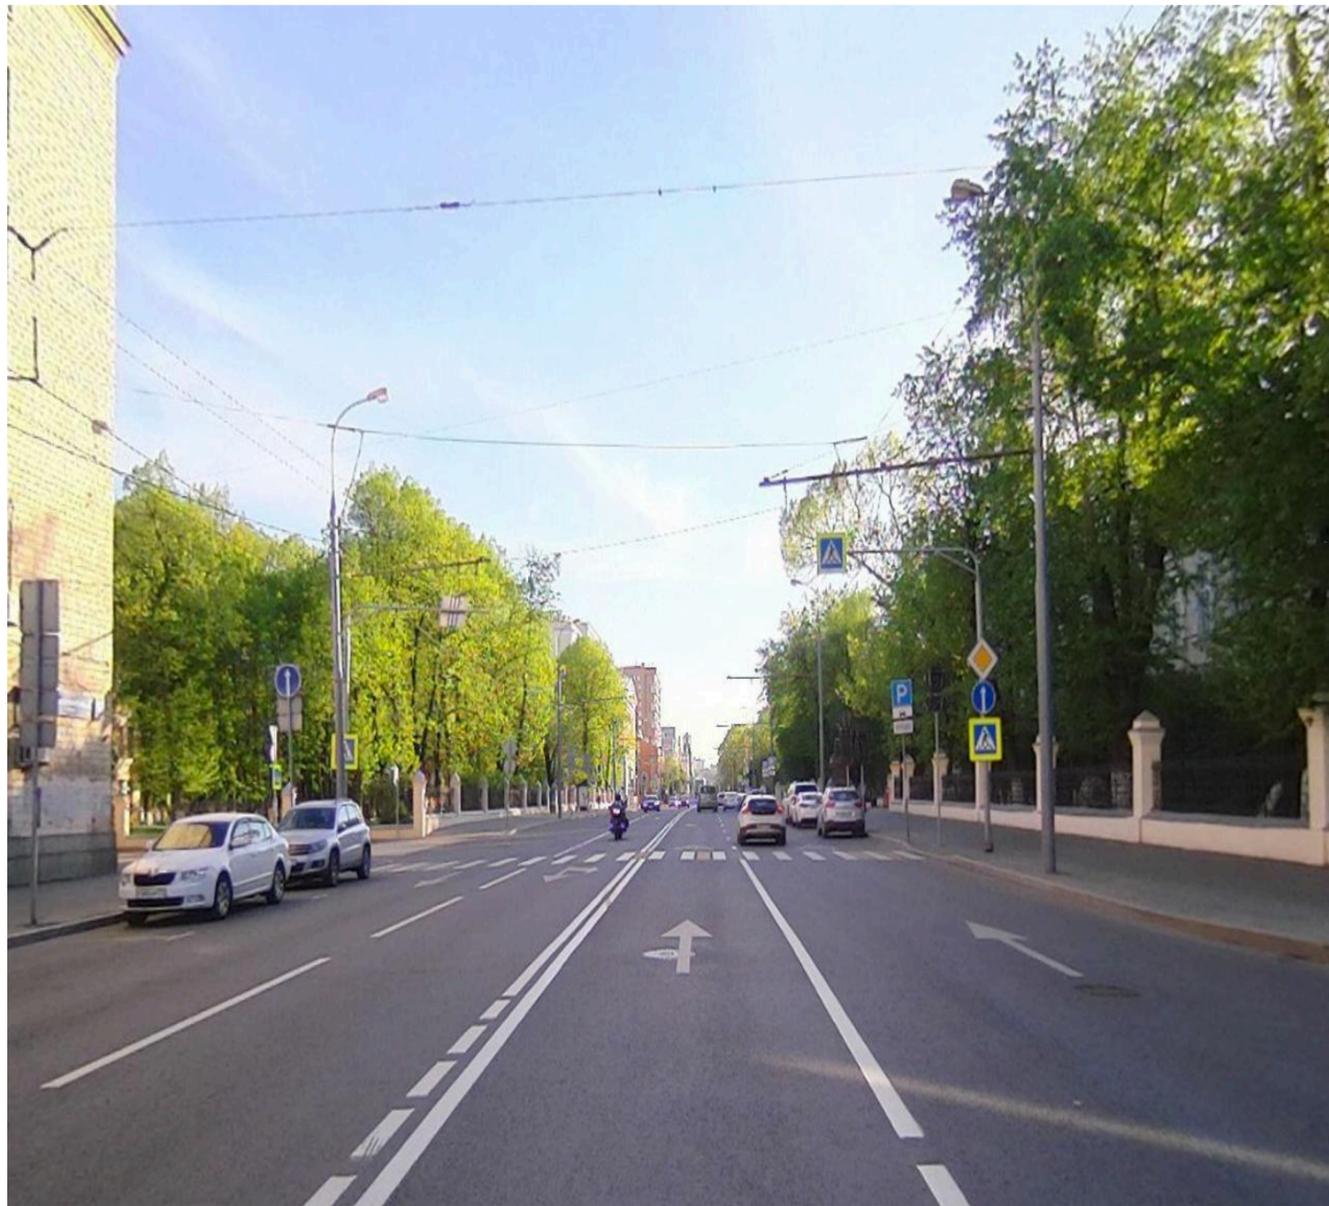
# Пример 2: ML и COVID-19



Были спроектированы сотни инструментов AI для распознавания covid-19. Они не сработали.

*[www.technologyreview.com](http://www.technologyreview.com)*

# Пример 3: Беспилотники



**Тогда откуда брать  
датасеты?**

# На потребность в новой разметке влияют



Частота  
перезапуска  
модели



«Потолок»  
модели



Изменения в  
окружающем  
мире

# Какие бывают подходы

- Синтетическая разметка
- Разметка внутри компании
- Аутсорсинг фрилансерам или вендорам
- Краудсорсинг

# Синтетические данные

Генерирование данных с нужными параметрами

✓ Меньше ограничений на использование

✓ Экономит деньги и время

✗ Часто оказываются значительно хуже реальных данных

# Разметка внутри компании

- ✓ Даёт предсказуемый результат
- ✓ Можно получить хорошую точность
- ✓ Прямое взаимодействие с разметчиками
  
- ✗ Долго
- ✗ Плохо масштабируется

# Аутсорсинг

Найм временных сотрудников или фрилансеров

Заказ у внешней команды

✓ Не отвлекает на задачу команду data science

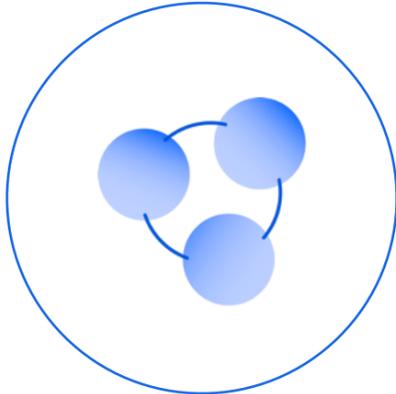
✓ Планирование ресурсов

✗ Меньше влияния на качество

✗ Может быть дорого или медленно

**Краудсорсинг**

# Краудсорсинг - это что?



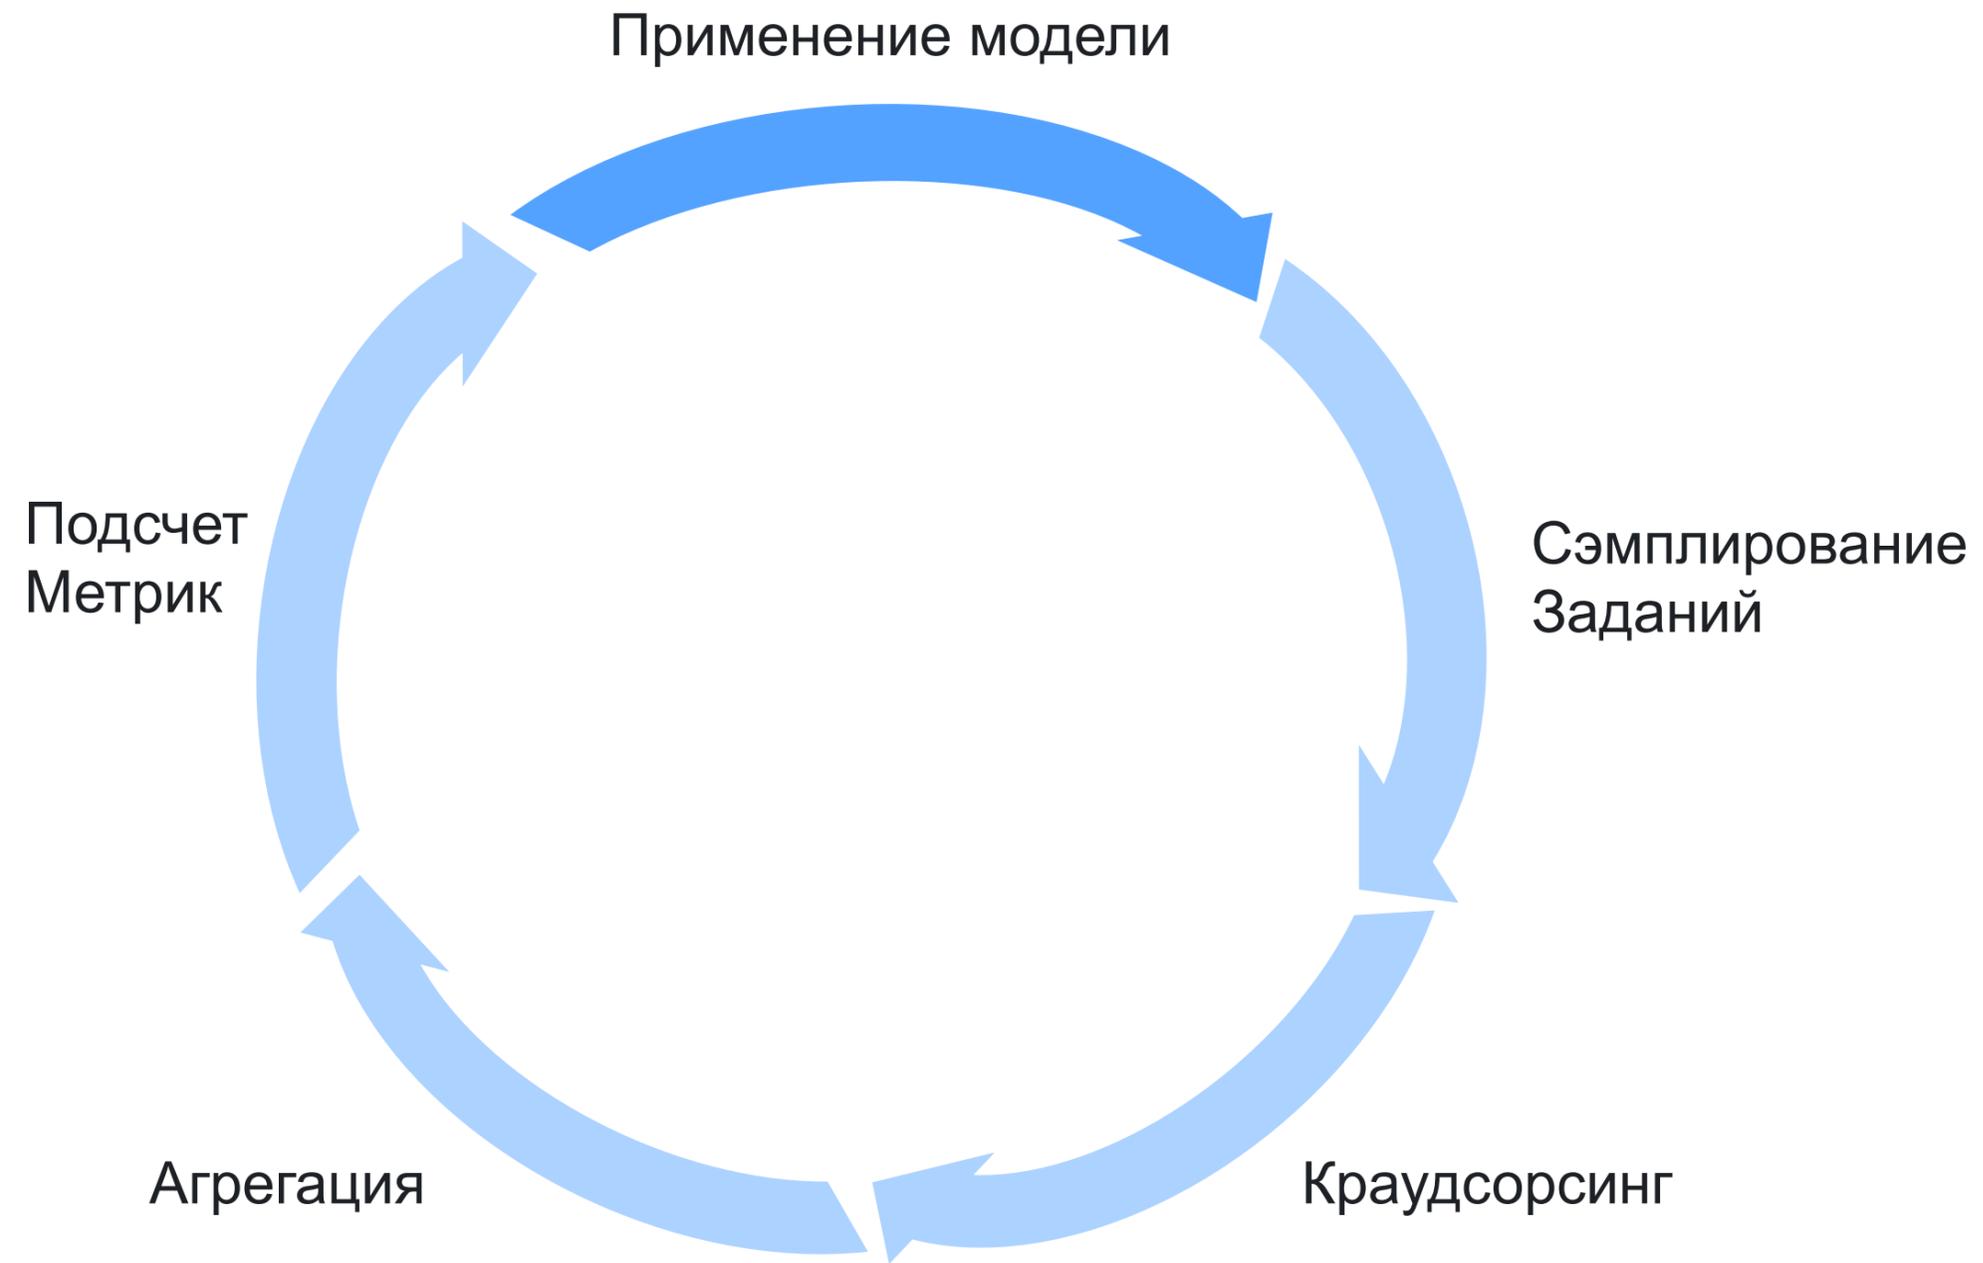
Абстрактное  
объемное задание

Облако исполнителей

Декомпозированная  
разметка

# Краудсорсинг

- ✓ Скорость
- ✓ Масштабируемость
- ✓ Настройка под задачу
- ✓ Экономичность
  
- ✗ Надо уметь добиваться «плюсов»
- ✗ Нужны инструменты контроля качества



# Реальные кейсы

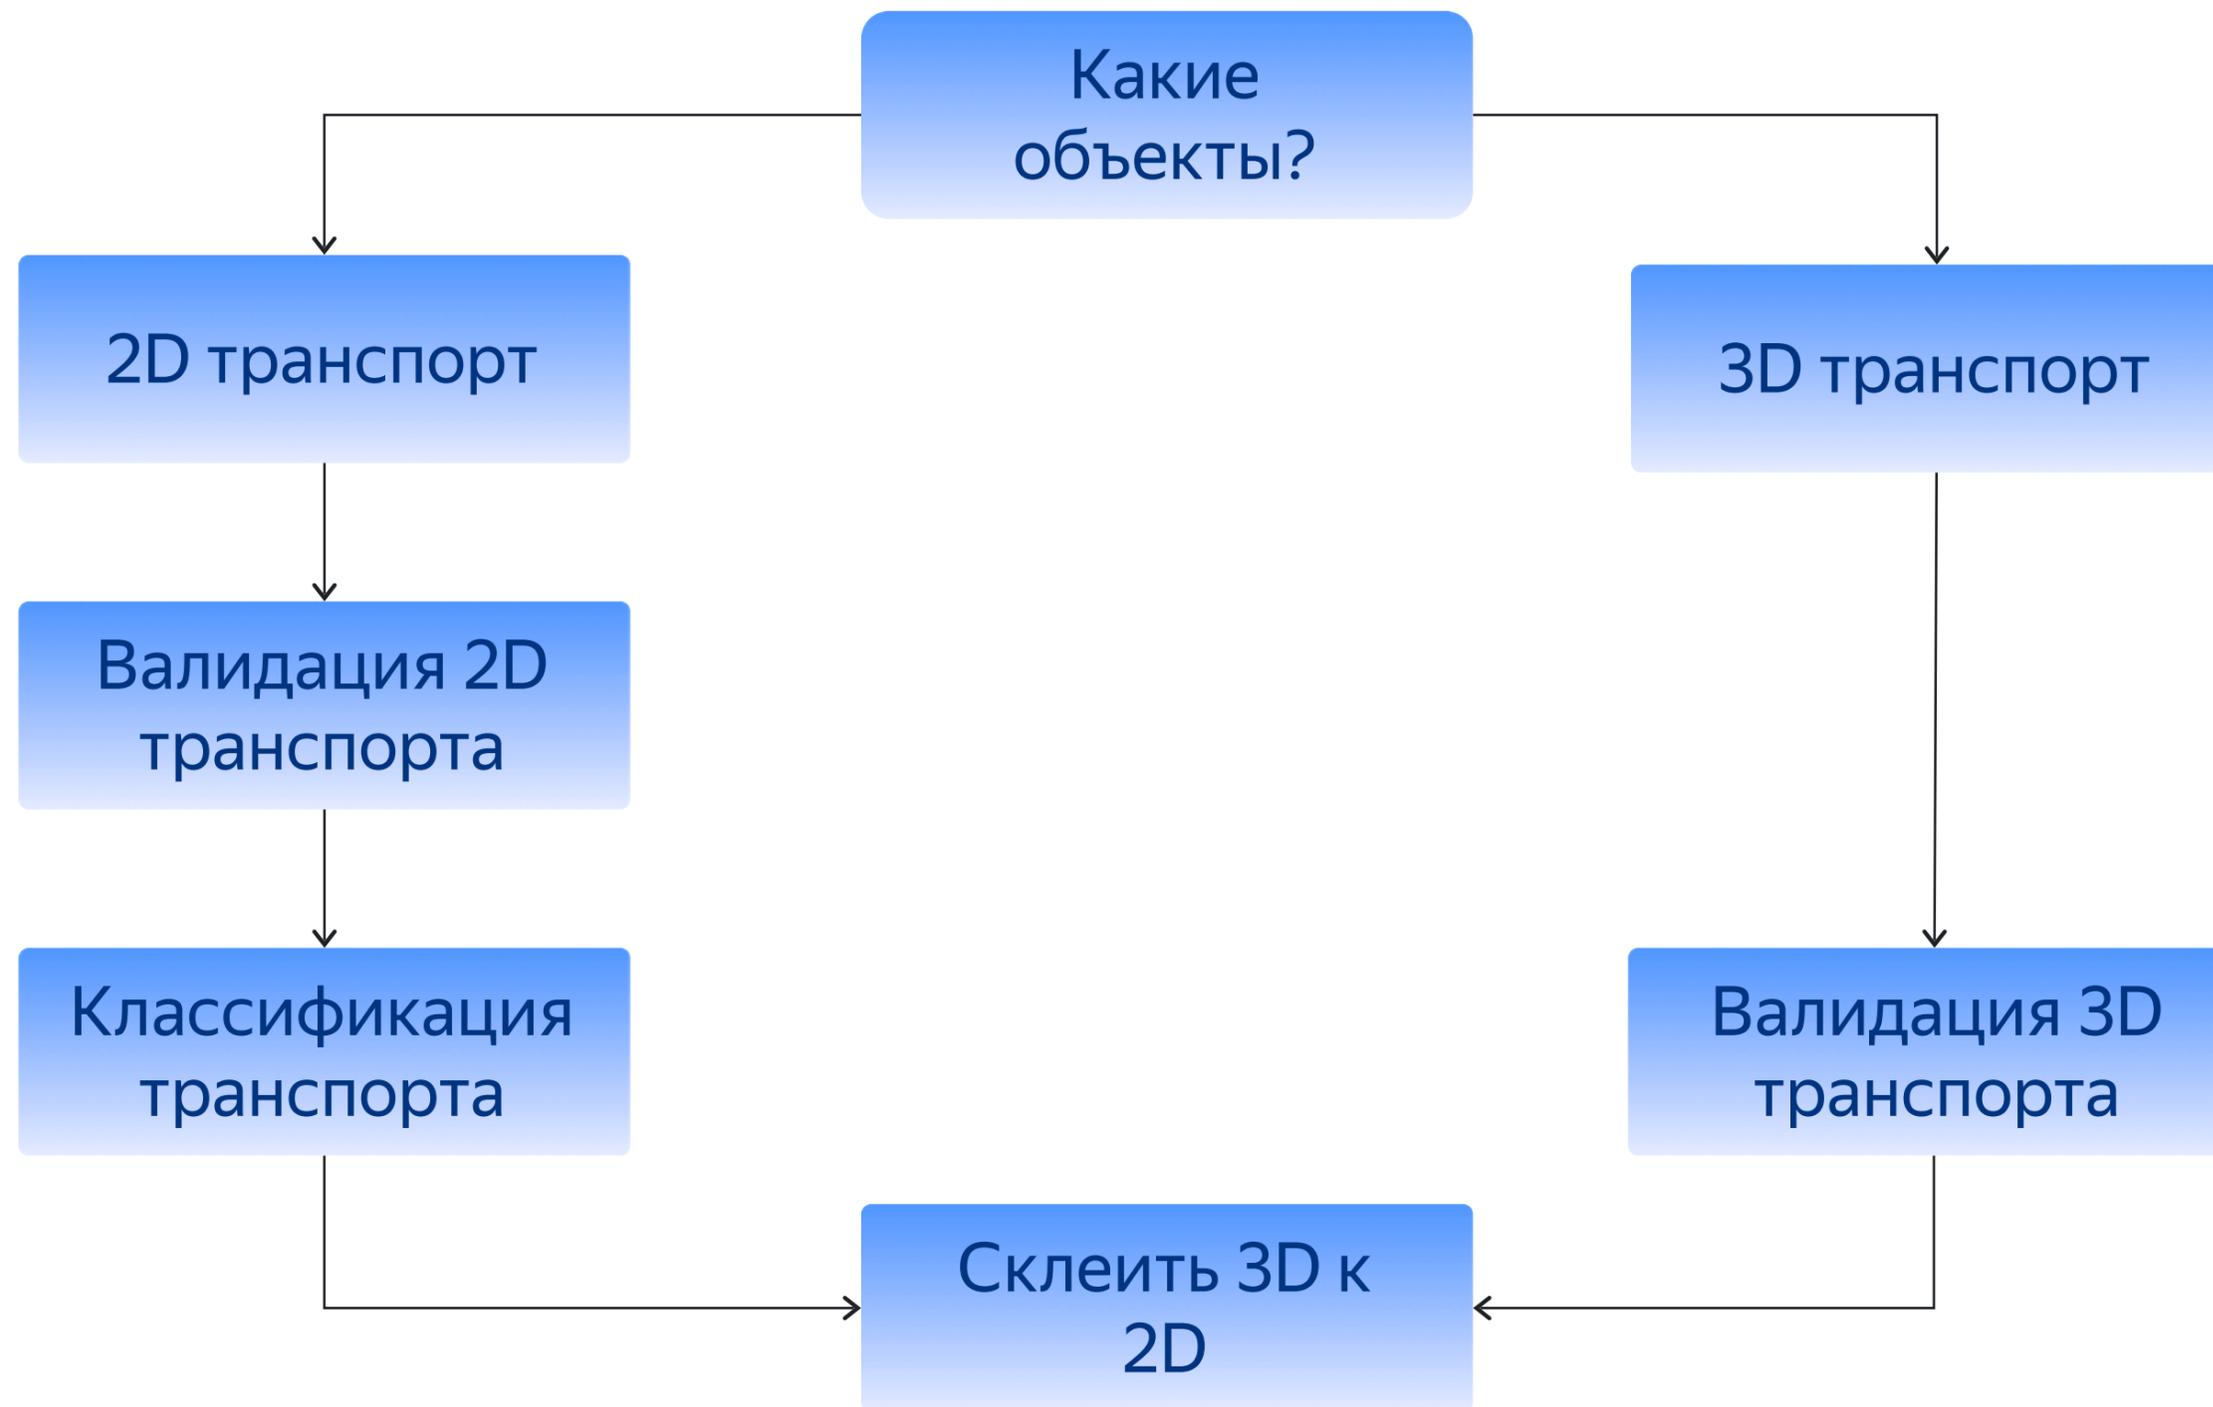
# Беспилотники

# Active learning

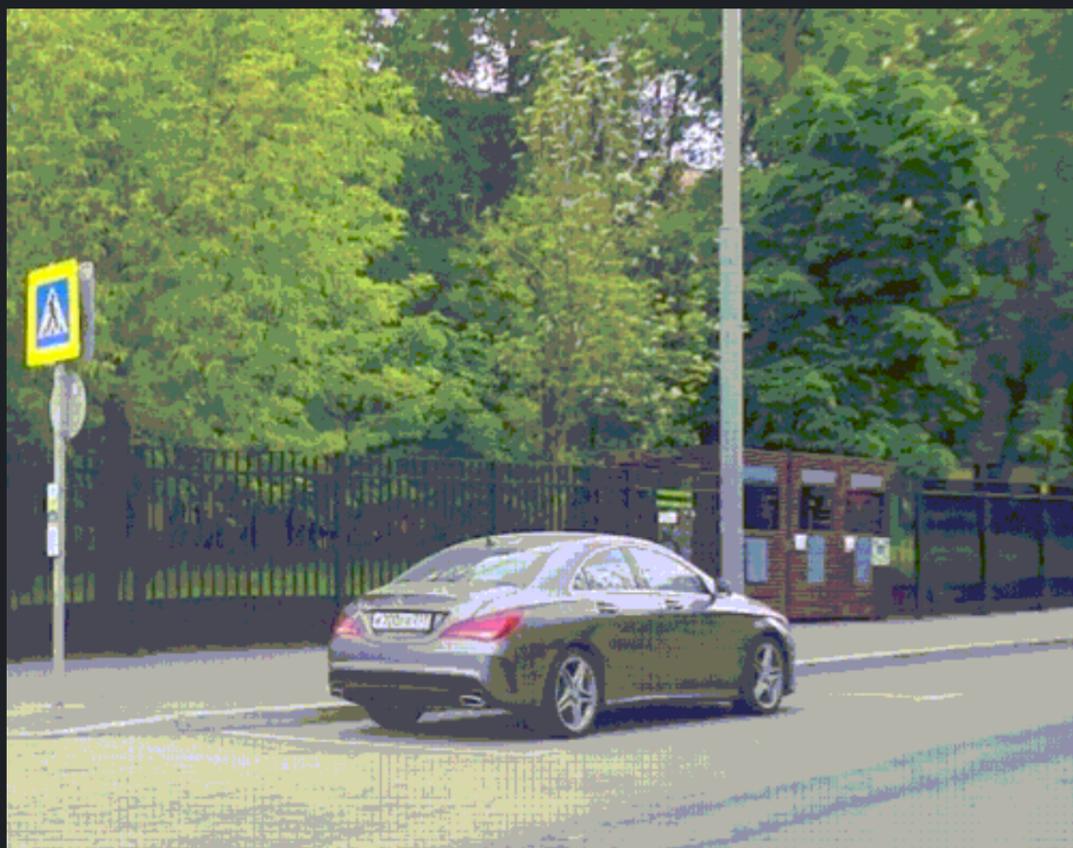


# Беспилотники: разметка 3D транспорта

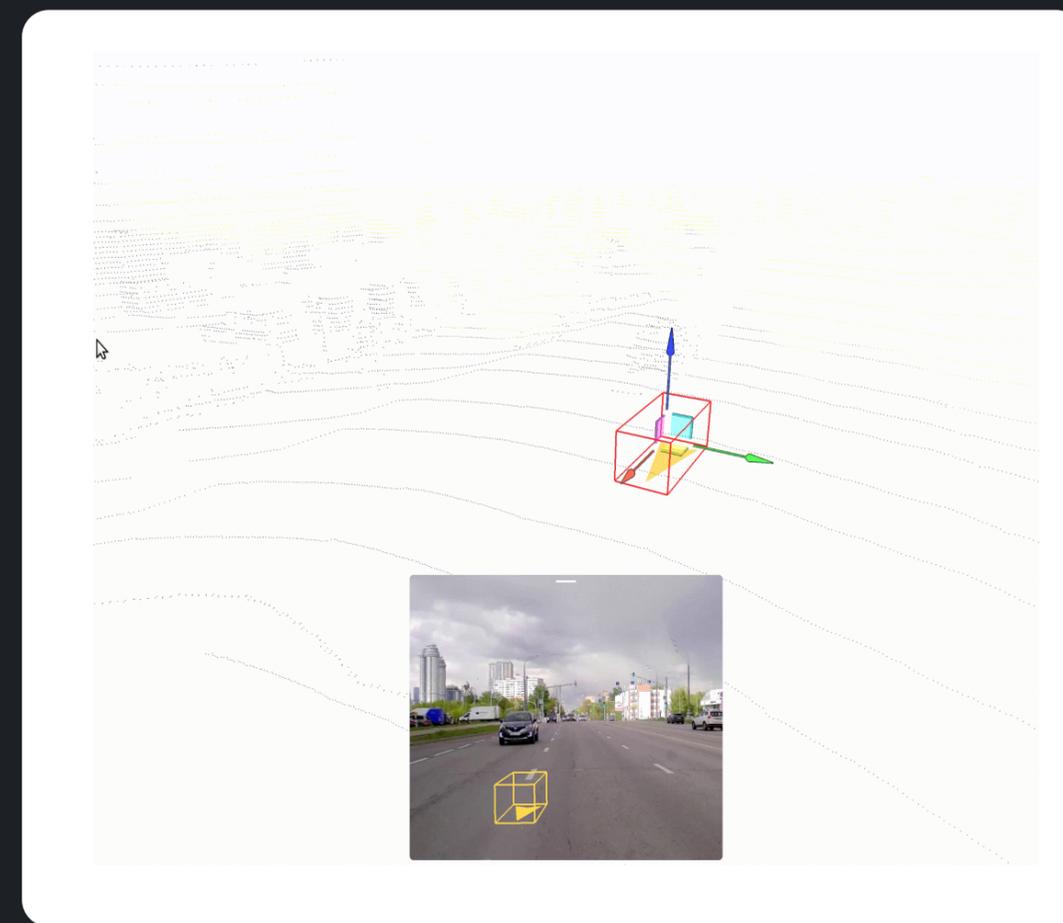
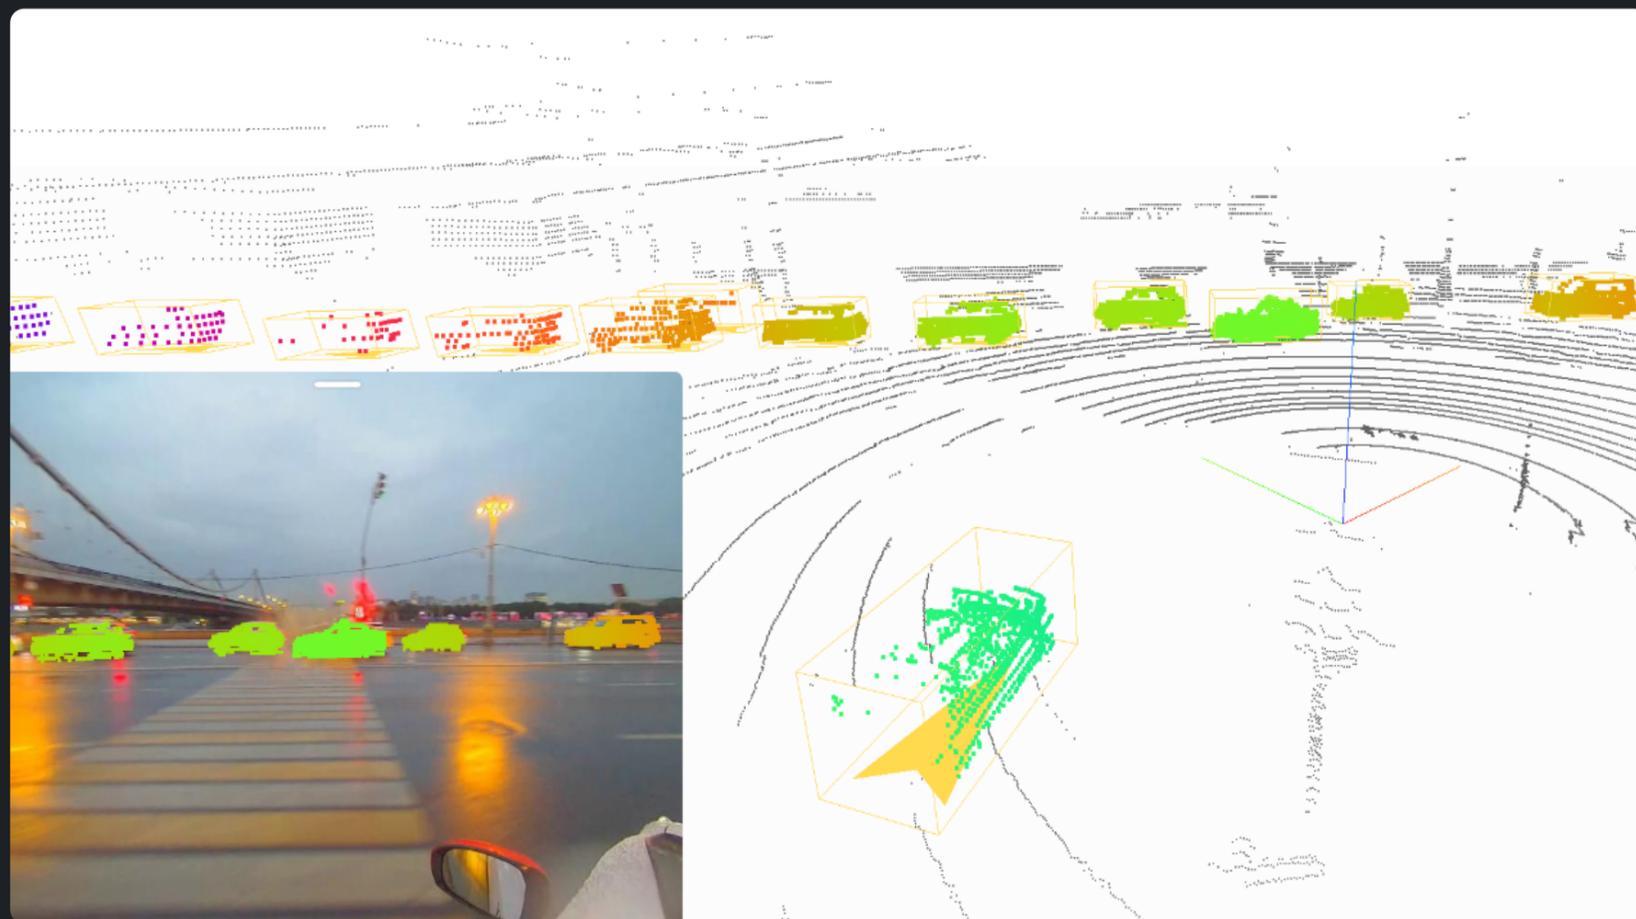
# Декомпозиция задачи



# Разметка 2D



# Разметка 3D-объектов



# Беспилотники: разметка видео

Для некоторых задач нужна информация о последовательности сцен, не об отдельных сценах

1. Трекинг объектов
2. Повторяющиеся процессы

# Интерфейс

toros.lanbox.ru

Preview pool tasks Back

Tasks In progress Messages

15:17 / \$0.02

Найдите все лампы перекрестков на видео-ролике

0.001 Левый выкл

0.000 Правый выкл

0.376 Левый выкл

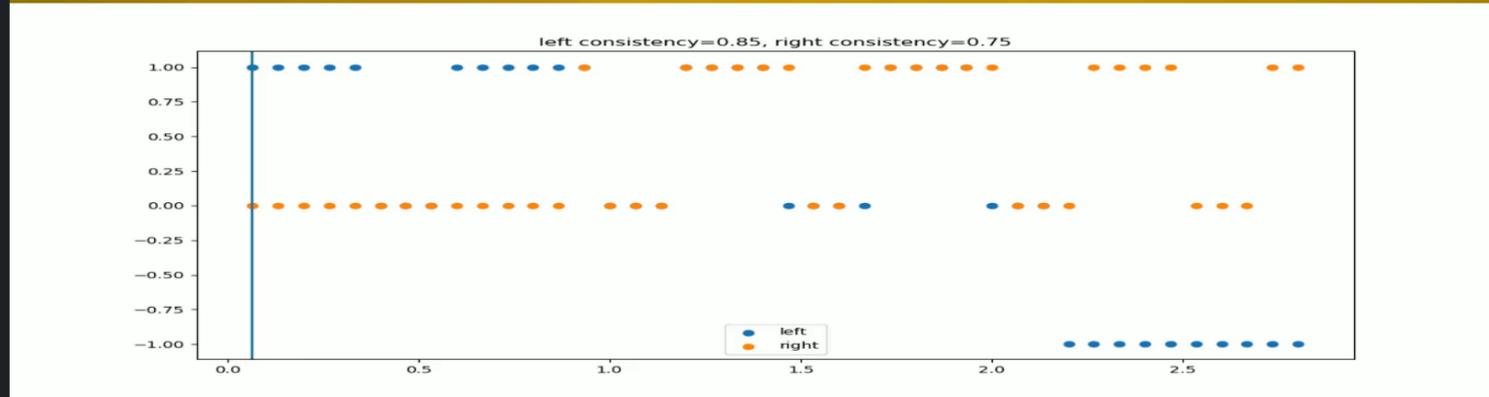
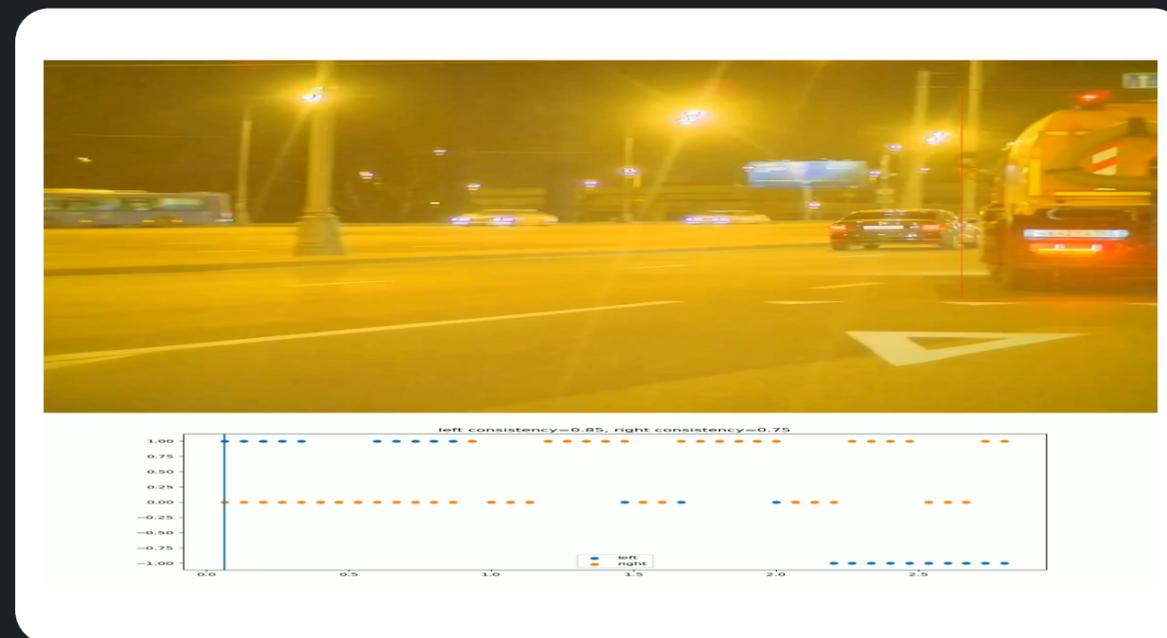
0.376 Правый выкл

Waiting for new events...

Report a problem

Submit

# Результаты разметки видео



**Алиса**

# Аннотирование

[Горячие клавиши](#)

**В данном задании надо записывать ВСЕ СЛОВА, произнесенные на записи, независимо от того искусственная речь или нет. Так же надо записывать ВСЕ СЛОВА ВСЕХ говорящих.**



Нет речи/неразборчиво

Введите слова, произнесённые на аудиозаписи

Alt+Тильда

Поиск

## Инструкция

В данном задании требуется прослушать звуковой отрывок и записать произнесенные слова в том порядке, в котором они прозвучали. Задание лучше выполнять в тишине, с наушниками. В случае необходимости прослушать запись необходимо несколько раз.

## Порядок выполнения задания

### ОБЩАЯ СТРАТЕГИЯ

Сначала записываем текст в соответствии с правилами ниже, потом выбираем нужную radio button из первых трех, а потом - проставляем галочки в оставшихся пяти чекбоксах.

Если на записи **есть речь**, определите количество говорящих, отметьте соответствующий вариант и запишите то, что вы услышали в поле "Текст аннотации". В тексте аннотации при этом должна содержаться только речь, обращенная к Алисе. Если есть сомнения, по умолчанию речь считаем обращенной к Алисе. Если есть речь, не направленная к Алисе, то выбираем вариант **"Есть речь, НЕ обращенная к Алисе"**.

### [Пример](#)

Если на аудиозаписи **нет речи**, говорящие издают нечленораздельные звуки, напевают мелодию без слов, либо вы не можете разобрать ни одного слова - отметьте вариант "Нет речи/неразборчиво".

Если часть речи можно расшифровать, **то расшифровываем понятные слова и неразборчивые заменяем символом "?"** (см. ниже).

**Даже если запрос вопросительный - в конце не ставим символ "?"**

Если на записи присутствуют голоса нескольких человек, слова которых можно разобрать, либо один человек говорит на фоне различной речи из телевизора, радио или на фоне речи "Алисы", необходимо записывать **ТОЛЬКО** основного говорящего. Обратите внимание: играющая из телевизора или радио музыка не считается речью, если Вы не можете различить отдельные слова.

**Алиса: релевантность**

# UE2E (Uber End-To-End)

Состояние станции на 2020-10-19 16:24:28 ▾

Экран: экран видеоплеера

Фильтрация контента: Умеренный

Местоположение пользователя: Люберцы, Москва и Московская область

Последняя прослушанная музыка: <https://music.yandex.ru/track/43202053>

*Сейчас воспроизведение поставлено на паузу*

Последний просмотренный сериал: "Потомки солнца" на ivi. Серия "Серия 4" (1 сезон 4 серия)

*Сейчас это видео воспроизводится на 32 минуте 10 секунде*

*Следующая серия в очереди: "Серия 5" (1 сезон 5 серия)*

Взаимодействие со станцией ▾

Запрос пользователя: пауза

Сценарий: Управление плеером

Голосовой ответ Алисы: Музыка и/или видео ставятся на паузу, если проигрывались

Оценка ▾

Корректен ли ответ и/или действие Алисы на последний запрос пользователя?

Да <sup>1</sup>  Частично <sup>2</sup>  Нет <sup>3</sup>

Алиса сообщает пользователю недостоверную информацию

# Попарное сравнение сессий

Текущая версия 56.9% screen\_09bf-479b21d0... 43.1% Новая версия

Какой телефон хотите? айфон одиннадцатый Давайте поищем Поискать в Яндексе телефон

Включаю плейлист Плейлист дня ВОСПРОИЗВЕСТИ Яндекс Музыка айфон одиннадцатый Ищу для вас ответ Поискать в Яндексе телефон

Комментарии выбравших "Текущая версия"

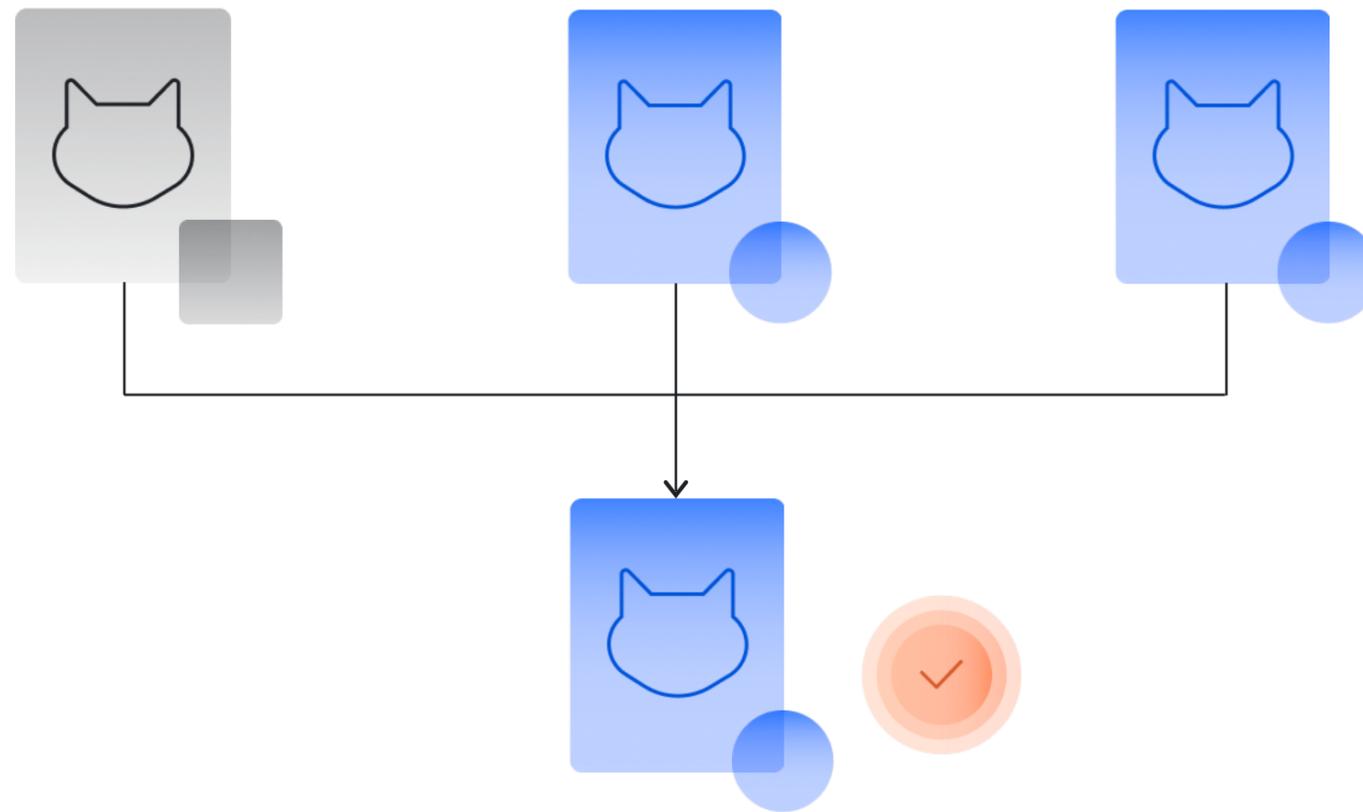
- Левый лучше потому-что человек может хочет купить телефон,а в правом он включает музыку,которая возможно и не нужна человеку в данный момент
- Ответ Алисы слева лучше, так как чётко отвечает на запрос пользователя по поводу поиска информации о телефоне айфоне 11
- Алиса уточняет модель телефона, не включает плейлист. После уточнения начинает поиск.
- Правый скриншот лучше, т.к. Алиса поняла тему, на которую интересуется пользователь.

Комментарии выбравших "Новая версия"

- Фраза ищу для вас ответ в этом варианте не так режет слух, вариант справа не понятн главное с кем собирается искать.
- Мне больше нравится диалог в правом варианте.
- Более содержательный диалог
- Интереснее вариант справа.
- нравится наличие плейлиста

**Как получить  
качественную  
разметку?**

# Перекрытие



**Как агрегировать  
краудсорсинговые  
аннотации?**

# Мнение большинства



# Взвешенное мнение большинства



Cat      Dog

1  
Качество в среднем:  
0.20  
Cat

2  
Качество в среднем:  
0.60  
Cat

3  
Качество в среднем:  
0.90  
Dog

Мнение большинства

|       |     |
|-------|-----|
| Cat   | Dog |
| 1     | 1   |
| 1     |     |
| <hr/> |     |
| 2     | 1   |
| Cat   |     |

Взвешенное мнение большинства

|                |                |
|----------------|----------------|
| Cat            | Dog            |
| $0.2 \times 1$ | $0.9 \times 1$ |
| $0.6 \times 1$ |                |
| <hr/>          |                |
| 0.8            | 0.9            |
|                | Dog            |

# Если данные не категориальные

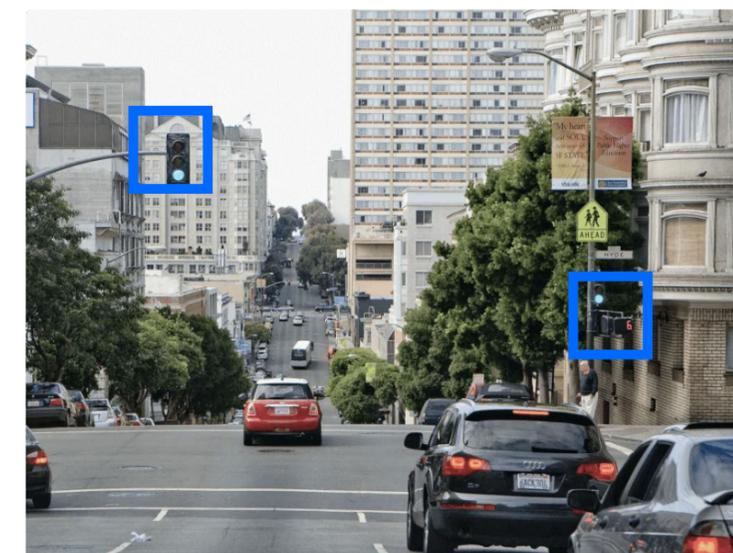
Попарные сравнения



Текст

{'a b c d', 'b z d e', 'b c d e f'}

Сегментации



# Crowd-Kit

# Интерфейсы & методы

## Crowd-Kit

- ▶ BaseClassificationAggregator fit()
- ▶ BaseEmbeddingsAggregator predict()
- ▶ BaseTextsAggregator  $\longrightarrow$  predict\_proba()
- ▶ BasePairwiseAggregator predict\_scores()
- ▶ BaseImageSegmentationAggregator fit\_predict()

# Входные данные

**Crowd-Kit**

- ▶ Ответ
- ▶ Исполнитель
- ▶ Задание



# Методы агрегации

## Crowd-Kit

### Категориальные данные

| Method             |
|--------------------|
| Majority Vote      |
| Dawid-Skene        |
| Gold Majority Vote |
| M-MSR              |
| Wawa               |
| Zero-Based Skill   |
| GLAD               |

### Текст

| Method |
|--------|
| RASA   |
| HRRASA |
| ROVER  |

### Сегментация

| Method            |
|-------------------|
| Segmentation MV   |
| Segmentation RASA |
| Segmentation EM   |

### Попарные сравнения

| Method              |
|---------------------|
| Bradley-Terry       |
| Noisy Bradley-Terry |

# Датасеты

## Crowd-Kit



Relevance 2



Relevance 5



Crowdspeech



IMBD-WIKI-SbS

```
▶ from crowdkit.datasets import get_datasets_list  
[name for name, description in get_datasets_list()]
```

```
['relevance-2',  
'relevance-5',  
'mscoco',  
'mscoco_small',  
'crowdspeech-dev-clean',  
'crowdspeech-test-clean',  
'crowdspeech-dev-other',  
'crowdspeech-test-other',  
'imdb-wiki-sbs',  
'nist-trec-relevance']
```

# Метрики

## Crowd-Kit

- ▶ Данные → alpha\_krippendorff  
consistency  
uncertainty
- ▶ Исполнители → accuracy\_on\_aggregates

**Какую задачу вы бы хотели  
попробовать решить с  
помощью краудсорсинга?**

# Спасибо!

**Евгения Суходольская**

Data Evangelist



[sukhodolskaya@toloka.ai](mailto:sukhodolskaya@toloka.ai)



<https://toloka.ai/>