

# Компьютерное зрение в *Wildberries*:

поиск товара по фотографии  
и детекция «главного»  
объекта

Евстифеев Степан, *Wildberries*  
Васильев Григорий, Яндекс

wildberries

# О спикерах



**Степан  
Евстифеев**

- Lead направления мультимодальных рекомендаций в Wildberries
- Магистр МГУ ВМК. Занимается Data Science с 2018 года
- До этого занимался компьютерным зрением в Сбере



**Григорий  
Васильев**

- Студент 4 курса МФТИ по направлению «Прикладная математика и информатика»
- ex CV-Engineer Wildberries
- Занимается ранжированием рекламы в Яндексе

# План выступления



Поиск по фото **раньше**

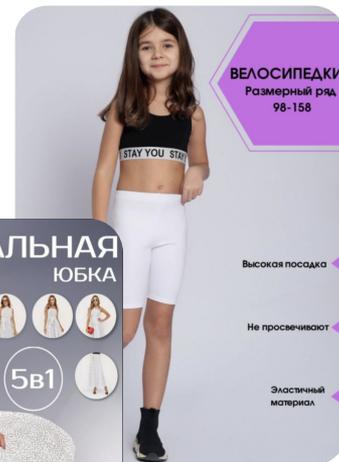
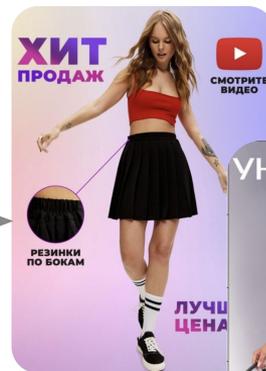
# Как работал поиск по фото

Входное изображение.  
Товар «юбка»



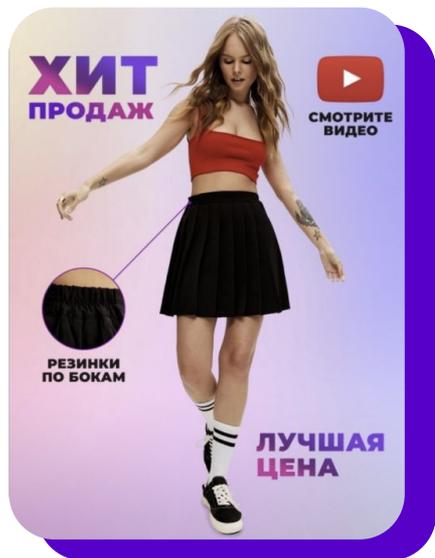
Сервис поиска  
визуально  
похожих

Выдача визуально похожих



# Проблемы выдачи

wildberries



Цвета одежды не совпадают



Несовпадение длины юбки



Общая композиция похожа, но товар не тот

# Постановка задачи

# Проблема и поиск решения

## Что есть?

В Wildberries реализованы алгоритмы поиска по фотографии. Но они учитывают контекст всей фотографии в карточке товара

## Какая существует проблема?

Учитывается лишняя информация: поза, текст, композиция и фон изображения, что **влияет на качество** выдачи поиска

## Что хотим получить?

Выделение **главного товара** с фотографии, который и будем использовать для поиска

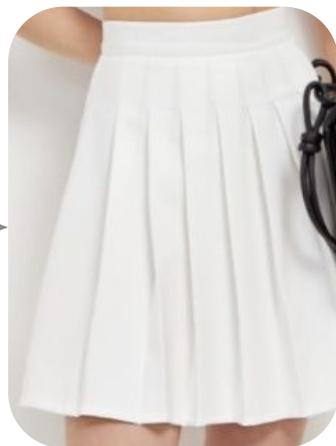
# Поиск по фото и выделение главного объекта

wildberries



Алгоритм выделения  
главного объекта

Главный объект на  
фотографии – юбка

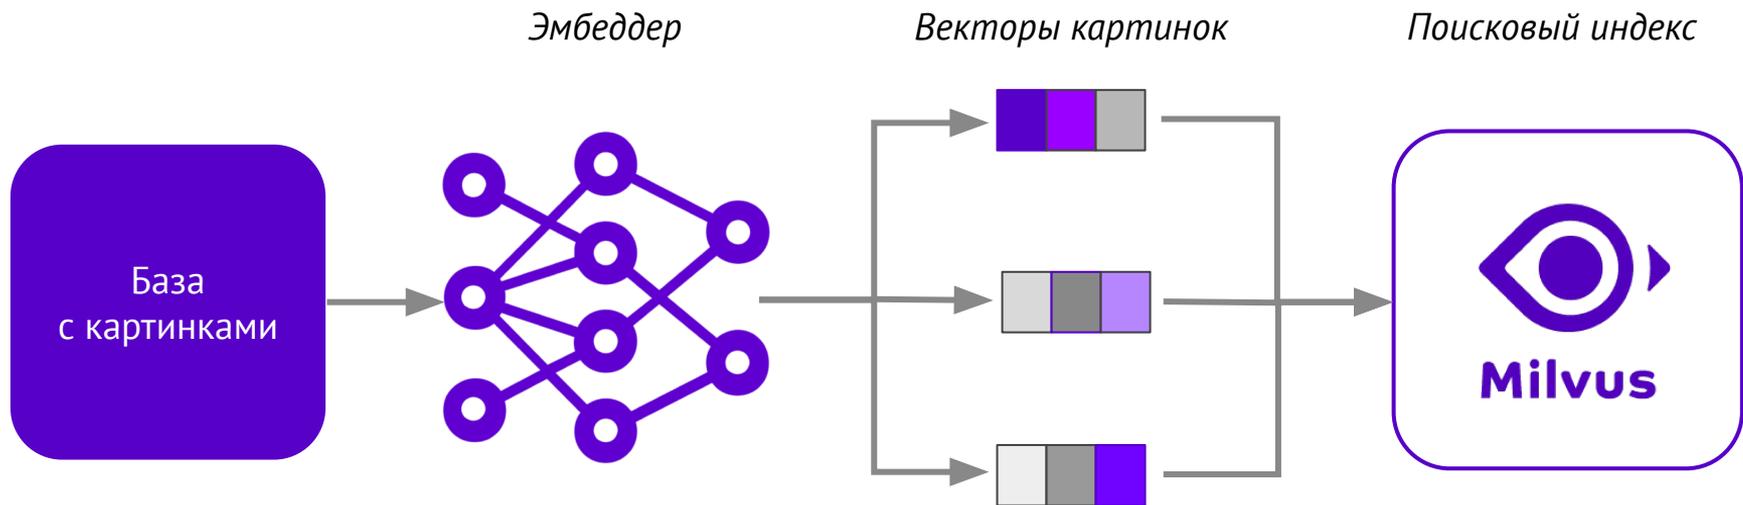


Сервис поиска  
визуально  
похожих

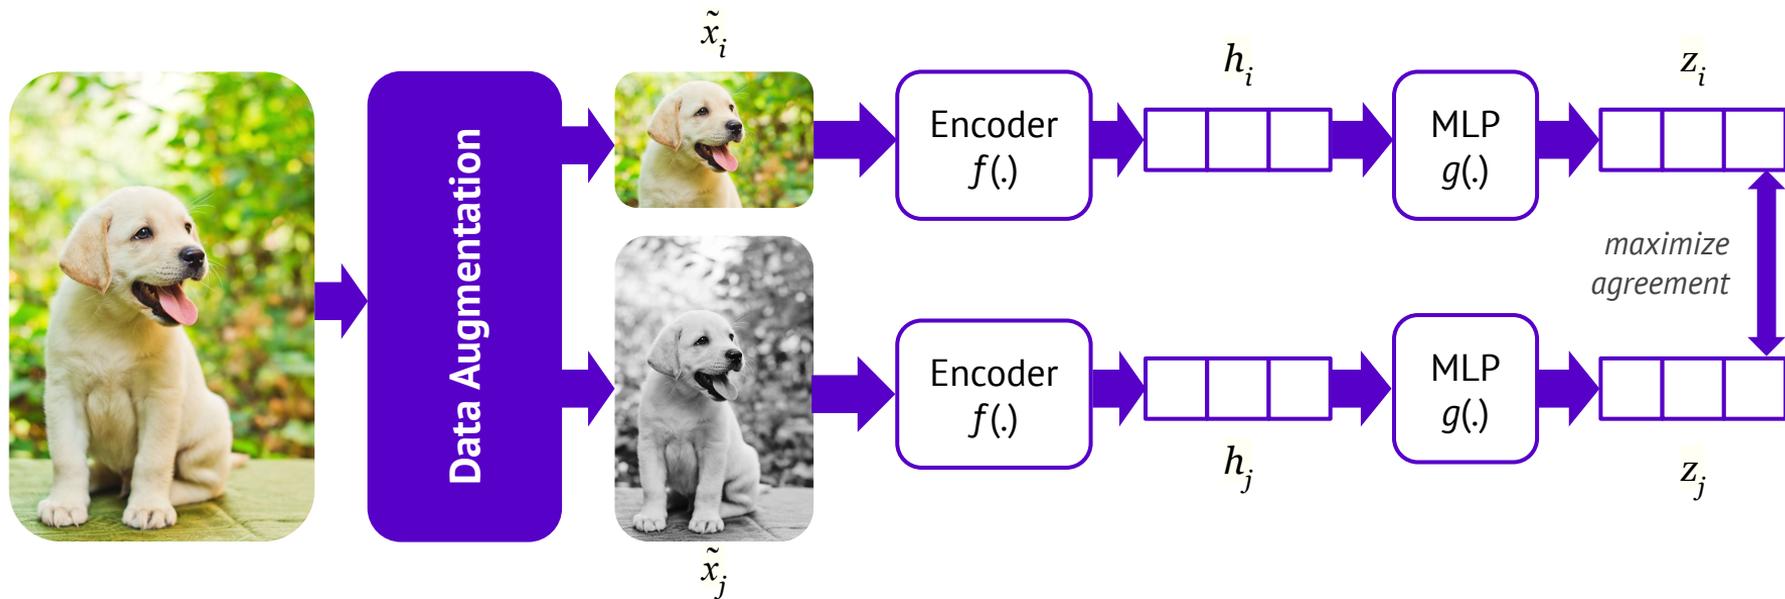


# Архитектура поиска товара по **изображению**

# Архитектура поиска по фото



# Архитектура поиска по фото. Эмбеддер



Процесс обучения визуально похожих товаров основан на процедуре из статьи [MoCo v2](#)

# Архитектура поиска по фото. Обучение

## SwinV2

Визуальный энкодер

**150 млн**

Картинок в обучении

## Вставка фона

Дополнительная аугментация

**82 млн**

Параметров

# Архитектура поиска по фото.

## Поисковый индекс

Поисковый индекс:  
**Milvus (GPU)**

**Inverted File Index**  
для поиска

**Квантуем** векторы для  
хранения

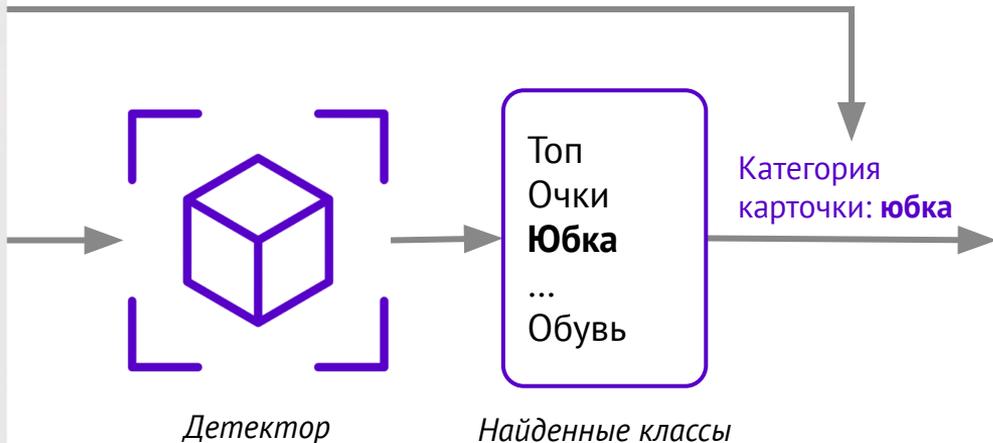
Количество картинок  
в индексе: **160 млн**

Скорость поиска  
похожих по 1 вектору:  
**200ms**

# Выделение **главного** объекта

# Выделение главного объекта через карточку товара

Карточка товара «юбка»



Главный объект



# Данные. Открытые датасеты

- Собрали и обработали почти все открытые датасеты с одеждой (самая продаваемая на WB категория товара)
- Классы датасетов мы отображаем в специально отобранные 13 классов, покрывающие 99% видов вещей, которые может надеть человек ;)

Открытые датасеты	Размер
DeepFashion (multimodal)	7к
DeepFashion (in-shop)	12к
Fashionpedia	50к
ModaNet	52к
Vcero	121к

# Данные. Label Studio

- В качестве платформы для разметки мы используем **Label Studio**
- Позволяет работать в разных доменах: текст, картинки, аудио
- Очень легко разобраться с UI ассессорам
- Мы размечаем полигонами: так хоть и дольше, но зато качественнее!

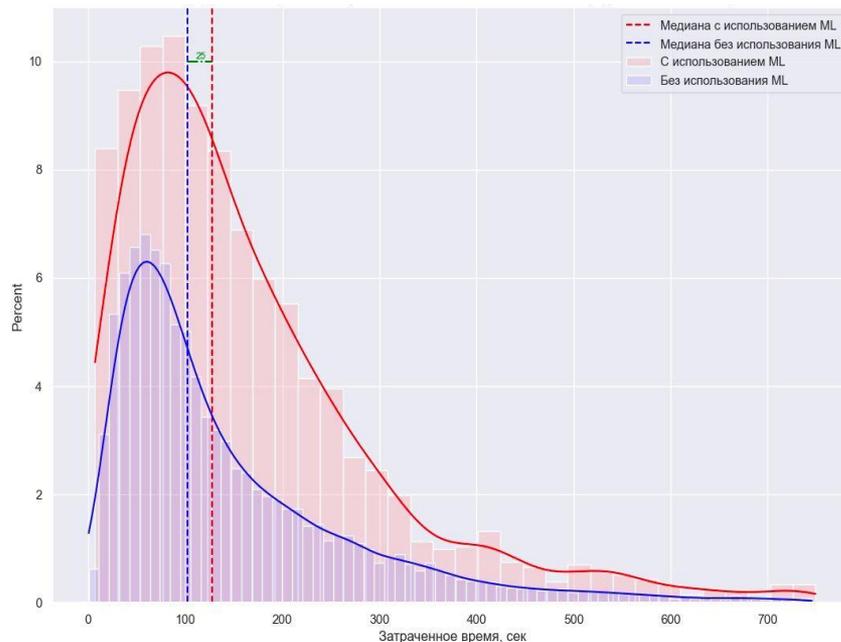
*Пример разметки в Label Studio*



# Данные. Авторазметка

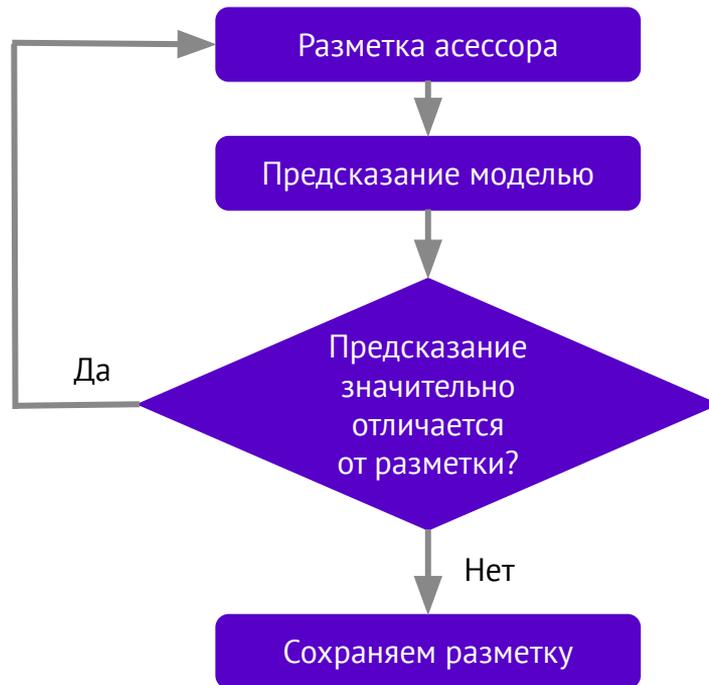
- Добавили кастомную разработку для **автогенерации разметки** с помощью ML
- Но в итоге это увеличило время разметки в среднем на 25 секунд!
- А дальше ассессоры стали пользоваться авторазметкой все реже

Распределение затраченного времени в зависимости от количества предсказаний в аннотации



# Данные. Active learning

- Используем своеобразный **active learning**
- Переразмечаем объекты, которые не совпадают с предсказаниями обученной модели
- В среднем **23%** из них оказываются действительно неправильно размеченными



# Данные. Разметка. Инструкция

wildberries

Важно писать очень подробную инструкцию!



Если не просить четко выделять границы объекта, то ассессоры и будут размечать «на глаз»



Сначала было не очевидно, что одна часть товара может быть «разделена» другим



Здесь решили выделить лицо в качестве предмета одежды

# Архитектура модели

- В качестве основного детектора используется модель семейства **YOLO**
- Обученную модель конвертируем в **ONNX** – это единый формат для представления моделей для деплоя
- А уже ONNX конвертируем в **TensorRT** – это оптимизированный формат моделей на видеокартах Nvidia

Формат модели	Скорость работы*
ONNX (CPU)	2.679 s
TorchScript	0.00984 s
<b>TensorRT</b>	<b>0.00596 s</b>

\*1 картинка 1024x1024

# Тестирование

- Когда проект становится большим и в нем есть различные модули, то часто бывает так, что при изменении одного кусочка кода он может сломаться в самых неожиданных местах
- Для того, чтобы этого избежать мы в каждом проекте пишем тесты на **pytest**
- Удобно использовать **fixture** для создания сложных объектов
- А **mock** позволяют эмулировать поведение объектов (например, задать определенные логиты у модели)

## Юнит-тесты

Помогают отловить баги в реализации логики модулей

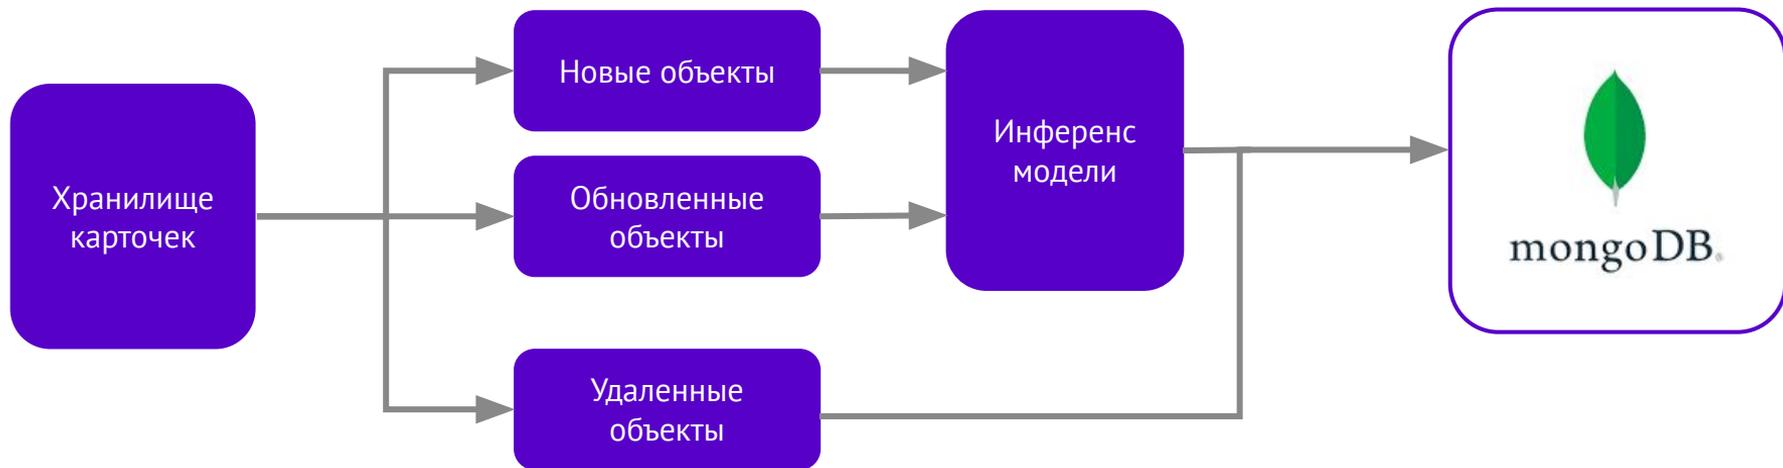
*Как-то тест нам помог найти странный баг с TensorRT, который при большом батче не падает с ошибкой, а дублирует предсказание для первого объекта для всех картинок в батче*

## Интеграционные тесты

Запускаются для всех моделей, которые добавлены в проект — метрики на фиксированном датасете не должны быть слишком низкие

# Интеграция с продом. Оффлайн пайплайн

Для обучения модели поиска по фото нужно рассчитать предсказания детектора для всех товаров WB

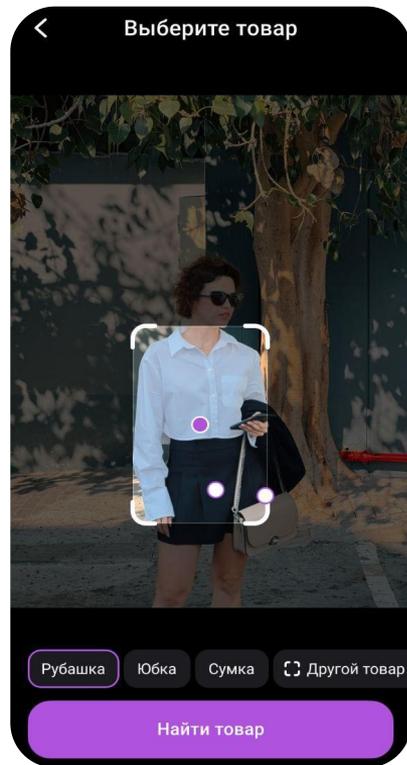


В качестве хранилища предсказаний мы используем [MongoDB](#). Запускаем пайплайн раз в сутки

# Интеграция с продом. API

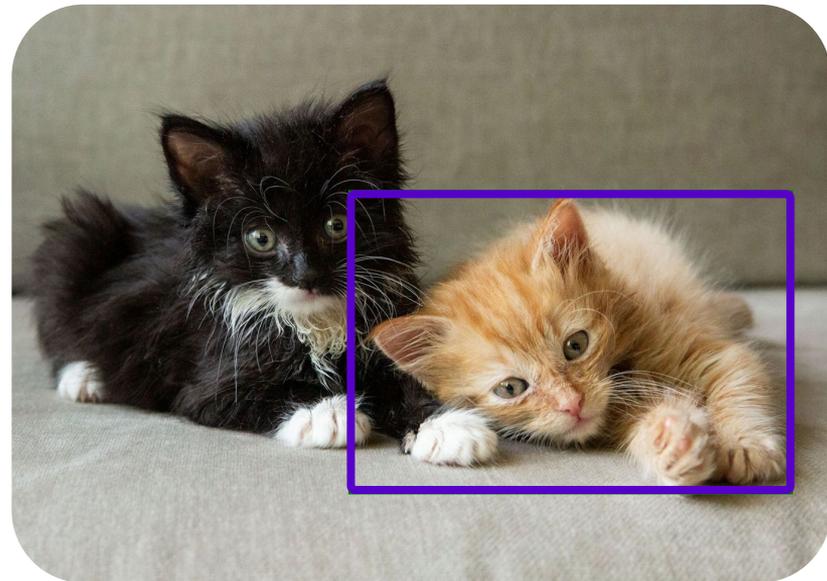
- Для помощи пользователю выбрать главный объект мы реализовали **API** и **UI**
- API реализован с помощью фреймворка **FastAPI**
- Для деплоя модели в онлайн мы используем веса модели TensorRT в инференс сервере **Triton**
- Он позволяет распределять нагрузку между GPU, а также эффективно делать инференс модели

*Дизайн интерфейса поиска по пользовательскому фото*



# Zero-shot detection

- Модель работает только с одеждой, но хочется расширить её и на другие категории
- Один из самых простых способов это сделать – использовать **zero-shot детекторы**
- Они могут по текстовому запросу (промπτу) найти интересующий объект на изображении
- Мы использовали 2 zero-shot детектора: **YOLO-World, OWLv2**



*Пример работы open-set детектора.  
В данном случае был промпт «right kitten»*

# Результаты

# Оффлайн-метрики Детектор

Метрики моделей на тестовой части

Модель	MAP@0.5:0.95	F1 Weighted	FP ratio*
YOLOv5	0.71	0.789	0.62
YOLOv8	0.70	0.778	0.59
YOLOv8 + аксессуары	<b>0.74</b>	0.799	0.69
<b>YOLOv8 + аксессуары + FP</b>	0.73	<b>0.813</b>	<b>0.03</b>
YOLO-World	0.31	0.395	0.46
OWLv2	0.42	0.437	-

\* посчитан на датасете, который не имеет предметов одежды

# Оффлайн-метрики

## Поиск по фото

Модель	Precision@10	F1 score
SwinV2 (полные картинки)	0.05	0.02
<b>SwinV2 (кропы)</b>	<b>0.11</b>	<b>0.06</b>

# A/B-тестирование

Эксперимент	Revenue	Add to cart	View Item	Orders
Добавили возможность выбрать пользователю главный объект из найденных	+1.1%	+4.5%	+6.71%	-0.53%
Обучили энкодер на поиск кропов в кропах	+4.83%	+4.58%	+5.71%	+3.29%

# Спасибо за внимание!



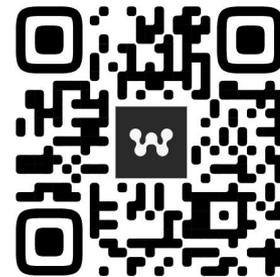
Telegram Евстифеева  
Степана: @minemile



Telegram Васильева  
Григория: @vasgreg



Блог WB TECH  
на Хабр



Telegram-канал  
WB Space