



Лаборатория компьютерной  
графики и мультимедиа  
ВМК МГУ имени М.В. Ломоносова

*Курс «Компьютерное зрение»*

# «Обучение метрик и поиск похожих изображений»

Антон Конушин и Тимур Мамедов

2025 год

# План лекции


---



1. Постановка задачи, датасеты и метрики
2. Metric Learning
3. Эффективный поиск

# Распознавание по лицу - верификация

---



На обоих изображениях один и тот же человек, или нет?

Базовая задача распознавания лиц, которую и человеку проще всего решать

# Распознавание человека



- «Watch list» - «белый» или «черный список»
  - Есть список людей с фотографиями
  - Необходимо определить, входит ли человек в этот список по его фотографии
- Сводим к попарному сравнению «запросов» с «изображениями из базы»
- Изображение может содержать лицо, портрет, ладонь, отпечаток пальца, всю фигуру

# Поиск полудубликатов




Полудубликаты (Near-duplicates) – слегка измененная версия изображения (ракурс, цвета)

# Поиск похожих изображений




- Или «поиск изображений по содержанию» (Content-based image retrieval)
- Есть коллекция изображений. Мы формулируем запрос в виде изображения-примера («найди то же самое»)



- Поиск по «визуальному сходству» изображения в целом или объектов в изображениях
- Чаще всего – нужно найти тот же самый объект, и другие похожие на него
- Классификация с открытым и заранее неизвестным набором классов

# Общая схема поиска похожих изображений



Ищем  
ближайших соседей по  
выбранной метрике



# Коллекции для распознавания человека



← → ⌂ ⓘ 10.10.9.21:8000/plugins/club/marking

+ Add Delete

2017-03-17 ⌂ 12:45:05

♂ 25 0.954  
19 G ✓

2017-03-17 ⌂ 12:43:20

♂ 21 0.993  
17 G ✓

2017-03-17 ⌂ 12:39:46

♂ 19 0.88  
1 G ✓

- Много вариантов:
  - Лицо
  - Радужка
  - Отпечаток пальцев
  - Фигура (и т.д.)
- Тоже многомилионных размеров и автоматическое построение
- У Гугла – 250 млн. изображений лиц

# Megaface challenge (2016)



## MegaFace and MF2: Million-Scale Face Recognition

The MegaFace challenge has concluded, reaching a benchmark performance of over 99%. Because its goals have been met, and ongoing maintenance of this platform would require considerable administrative effort, MegaFace is being decommissioned and MegaFace data are no longer being distributed.



### Distractors

**1 Million** Photos

**690,572** Unique Users

### Training Set

**4.7 Million** Photos

**672,057** Unique Identities

7 Mean photos / person (3 min, 2469 max)


### Test Sets

**FaceScrub** Celebrities

**FGNet** Age-invariant non-celebrities



# Датасет Oxford Buildings dataset



- Oxford5K
  - 5062 изображения 1024x768 достопримечательностей (landmark) Оксфорда
- 100K и 1M
  - коллекции изображений-дистракторов по самым популярным во flickr запросам

- 55 изображений запросов – по 5 изображений на 11 достопримечательностей
- По каждому запросу база размечена (Good – хорошо видно, OK - > 25%, Junk <25%, Absent – не видно)


# Google Landmarks



- Сбор коллекций в полуавтоматическом режиме путем запросов к поисковой системе
- 762k изображений в индексе, 4.1M изображений для обучения, 200к достопримечательностей
- Получены из Wikimedia, полуавтоматическая разметка, 800 человеко-часов
- Всего 118к тестовых запросов



# Метрики качества – Recall@R



- R – длина выдаваемого списка
- Recall@R – вероятность наличия истинного соседа в списке длины R
- Функцию можно сэмплировать (Recall@1, Recall@10) или усреднять тAP


# План лекции

---



1. Постановка задачи, датасеты и метрики
2. Metric Learning
3. Эффективный поиск


# Contrastive loss



$$\mathcal{L}_{\text{cont}}(x_1, x_2, \theta) = \begin{cases} \mathcal{D}_{f_\theta}^2(x_1, x_2), & y_1 = y_2 \\ \max(0, \alpha - \mathcal{D}_{f_\theta}^2(x_1, x_2)), & y_1 \neq y_2 \end{cases}$$

- Пришли из «сиамских» сетей
- Минимизируем расстояние между примерами одного класса
- Требуем чтобы расстояние между примерами разных классов было больше параметра а

# Triplet loss



**Loss function:**  $\mathcal{L}_{\text{triplet}} = \max \left( 0, \mathcal{D}_{f_\theta}^2(x_a, x_p) - \mathcal{D}_{f_\theta}^2(x_a, x_n) + \alpha \right)$



**Training:** for  $x_a$  choose  $\arg \max \mathcal{D}_{f_\theta}(x_a, x_p)$  and  $\arg \min \mathcal{D}_{f_\theta}(x_a, x_n)$  online from a large batch s.t.

$$\mathcal{D}_{f_\theta}(x_a, x_n) < \mathcal{D}_{f_\theta}(x_a, x_p) + \alpha$$

# Center loss



Пример на  
MNIST




$$\mathcal{L} = \mathcal{L}_S + \lambda \mathcal{L}_C$$

$$\mathcal{L}_C = \sum_{i=1}^m \|x_i - c_{y_i}\|_2^2$$

**Обучение:** обновляем центры  $C_{y_i}$  после шага градиентного спуска медленно с параметром  $\alpha = 0.99$

# SphereFace




Loss Function	Decision Boundary
Softmax Loss	$(W_1 - W_2)\mathbf{x} + b_1 - b_2 = 0$
Modified Softmax Loss	$\ \mathbf{x}\ (\cos \theta_1 - \cos \theta_2) = 0$
A-Softmax Loss	$\ \mathbf{x}\ (\cos m\theta_1 - \cos m\theta_2) = 0$ for class 1 $\ \mathbf{x}\ (\cos \theta_1 - \cos m\theta_2) = 0$ for class 2

Table 1: Comparison of decision boundaries in binary case. Note that,  $\theta_i$  is the angle between  $W_i$  and  $\mathbf{x}$ .


$$L_{\text{modified}} = \frac{1}{N} \sum_i -\log \left( \frac{e^{\|\mathbf{x}_i\| \cos(\theta_{y_i, i})}}{\sum_j e^{\|\mathbf{x}_i\| \cos(\theta_{j, i})}} \right)$$

$$L_{\text{ang}} = \frac{1}{N} \sum_i -\log \left( \frac{e^{\|\mathbf{x}_i\| \cos(m\theta_{y_i, i})}}{e^{\|\mathbf{x}_i\| \cos(m\theta_{y_i, i})} + \sum_{j \neq y_i} e^{\|\mathbf{x}_i\| \cos(\theta_{j, i})}} \right)$$





# CosFace, ArcFace



$$L_{lmc} = \frac{1}{N} \sum_i -\log \frac{e^{s(\cos(\theta_{y_i, i}) - m)}}{e^{s(\cos(\theta_{y_i, i}) - m)} + \sum_{j \neq y_i} e^{s \cos(\theta_{j, i})}}$$

$$L_3 = -\frac{1}{N} \sum_{i=1}^N \log \frac{e^{s(\cos(\theta_{y_i} + m))}}{e^{s(\cos(\theta_{y_i} + m))} + \sum_{j=1, j \neq y_i}^n e^{s \cos \theta_j}}$$

Wang et al. CosFace: Large Margin Cosine Loss for Deep Face Recognition. CVPR 2018  
Deng et al. ArcFace: Additive Angular Margin Loss for Deep Face Recognition. CVPR 2019

# План лекции


---



1. Постановка задачи, датасеты и метрики
2. Metric Learning
3. Эффективный поиск




# Инвертированный индекс




- **Построение:** применяем k-means для разбиения изображений на  $k$  кластеров.  $k$  центроидов (codewords) образуют codebook. Храним  $k$  списков с ID изображений в RAM
- **Поиск:** по запросу  $q$ , найдем несколько ближайших codewords. Возвращаем все ID из соответствующих списков.

# Product quantization (PQ)



- **Простроение:**
  - Разобьём вектор  $x$  длины  $D$  на  $m$  частей
  - Применим K-means к каждому отдельно
- **Сравнение с K-means:**
  - $kD$  и  $mk^*(D/m)=k^{1/m}D$
  - Обычно  $k^*=256$  (1 байт)

# Hierarchical Navigable Small World



Грубая оценка точности

Поиск за  $O(\log N)$

Построение за  $O(N \log N)$

Память: 60-450 байт/объект



# Вариант общего метода

1. Строим инвертированный индекс с большим  $K = 2^{20}$
2. В каждом кластере кодируют остаточные вектора с помощью PQ
3. Применяем HNSW для выбора кластеров при поиске

Method	$K$	DEEP1B					SIFT1B				
		R@1	R@10	R@100	t	Mem	R@1	R@10	R@100	t	Mem
O-Multi-D-OADC[24]	$2^{14}$	0.397	0.766	0.909	8.5	17.34	0.360	0.792	0.901	5	17.34
Multi-LOPQ[4]	$2^{14}$	0.41	0.79	-	20	18.68	<b>0.454</b>	<b>0.862</b>	0.908	19	19.22
GNOIMI[5]	$2^{14}$	0.45	0.81	-	20	19.75	-	-	-	-	-
IVFOADC+G+P	$2^{20}$	<b>0.452</b>	<b>0.832</b>	<b>0.947</b>	<b>3.3</b>	17.87	0.405	0.851	<b>0.957</b>	<b>3.5</b>	18

**Table 4.** Comparison to the previous works for 16-byte codes. The search runtimes are reported in milliseconds. We also provide the memory per point required by the retrieval systems (the numbers are in bytes and do not include 4 bytes for point ids).

# Резюме

---



Мы рассмотрели три компонента систем поиска:

1. Постановки задач и датасеты
2. Функции потерь для обучения метрик, которые заставляют признаки лежать в компактных многообразиях (manifolds)
3. Приближенные методы поиска ближайших соседей для масштабных задач поиска по картинкам