




256 оттенков серого




(кратко о распознавании образов)

Богомолов Антон



Лена Сёдерберг


test lenna image




Трудности анализа изображений

Компьютер

```
0 0 95 128 255 96 98 68 89 0 0
78 86 0 255 89 80 89 89 255
255 255 89 80 89 89 255 253
255 89 80 89 89 252 250 0 0
0 89 80 89 89 255 253 3 5 98
255 249 248 89 80 89 89 252
```



Человек




Цветные изображения


Монохромные изображения – двумерный массив чисел




Цветное изображение - серия монохромных изображений (серия массивов)




=



Зеленый



Синий



Красный

Распознавание образов


Распознавание образов – отнесение исходных данных к определенному классу с помощью выделения существенных признаков или свойств

Класс – множество объектов, имеющие общие свойства.

Классификация – процедура принятия решения о принадлежности объекта к одному из классов согласно измерению отличительных **признаков (характеристик)** объекта



Исходное изображение



Вычисление
признаков объекта



Кошка

Птица


Классификация

Трудности анализа изображений

Изображение одних и тех же объектов могут сильно различаться при разных условиях.



Разные ракурсы (точки наблюдения)



Освещение



Форма объектов



Движение

Трудности анализа изображений

Изображение одних и тех же объектов могут сильно различаться при разных условиях.



Фон



Перекрытие



Внутриклассовая изменчивость

Особенности распознавания объектов человеком



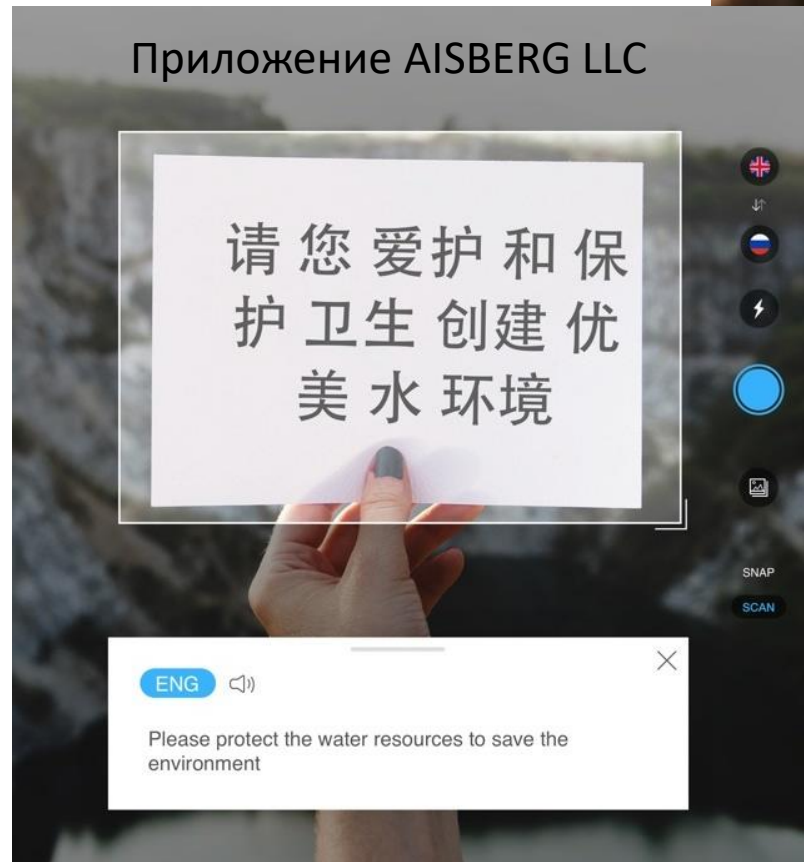
Большое количество примеров одного класса
(богатый опыт распознавания)




Контекст


Самолет? Нет, вид ч/з кружку

Системы распознавания образов





Кариотипирование




invdup (13 or 14 or 15 or 21 or 22)


Для анализа кариотипа человека - это отнесение хромосомы к одному из 25 классов (22 аутосомы, половые хромосомы и класс выбросов)

Гайнер и др. Комплексная диагностика хромосомной патологии – деривата хромосомы 4 и малой сверхчисленной маркерной хромосомы. // Мед. Генетика 2017


Общая схема анализа изображений хромосом





Типы признаков объектов



Характеристики для классификации хромосом



Подготовка к вычислению профиля бэндов




Построение
серединной линии
хромосомы
вручную

Построение
перпендикуляров к
серединной линии

Бэнд - участок хромосомы, отличающийся по интенсивности окрашивания от соседних

Серединная (центральная) линия - представляет собой геометрическое место точек плоскости, равноудаленных от границы объекта




Изображения:

Khan et al. Robust Band Profile Extraction Using Constrained Nonparametric Machine-Learning Technique // IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING, 2010

Sethakulvichai et al. Estimation of Band Level Resolutions of Human Chromosome Images // JCSSE 2012


Профили плотности, формы и бэндов



Профиль плотности (density profile)

$$P(y) = \left(\sum_{i=1}^n g_i \right) / n,$$

g - интенсивность сигнала в точке i
 n - количество точек в перпендикуляре



Профиль формы (shape profile) – количество пикселей в перпендикуляре


Профиль бэндов (band profile)

$$N(y) = [P(y-1), P(y), P(y+1)];$$

$$\text{DIFMAX} = \text{MAX}[N(y)] - P(y);$$

$$\text{DIFMIN} = P(y) - \text{MIN}[N(y)];$$


$$\text{ID}(y) = \text{NF}[P(y)] = \begin{cases} P(y) + \frac{\text{DIFMAX}}{R} & \text{If } \text{DIFMAX} \leq \text{DIFMIN} \\ P(y) - \frac{\text{DIFMIN}}{R} & \text{If } \text{DIFMIN} < \text{DIFMAX} \end{cases}$$



Геометрические характеристики


Длина хромосомы – количество точек в срединной линии (обычно рассматривается относительная длина рассматривается как отношение длины деленное на общую длину хромосом)

Центромерный индекс – отношение короткого плеча к общей длины хромосомы



Поиск центромеры

Анализ кривизны границы




Mohammadi 2014

Поиск на основе профиля формы




Wang et al. 2008

Метод проекций




Moradi et al. 2003

Принцип флуоресцентной гибридизации *in situ* (FISH)



ДНК-пробы - меченные фрагменты ДНК


Преимущество FISH



Откуда дополнительный
хромосомный материал?




Ответ дает FISH



Двадцатичетырехцветная FISH

24-цветная FISH – комбинаторное мечение, при котором ДНК-пробы метятся не одним флуорохромом, а их комбинацией.



Цветовая информация

- Интенсивность сигнала каждого отдельного флуорохрома в пикселе изображения
- Средняя интенсивность сигнала каждого отдельного флуорохрома в пикселях объекта
- Стандартное отклонение интенсивности сигнала каждого отдельного флуорохрома в пикселях объекта

Методы классификации

Обучение по подобию - методы, использующие приближение и расстояние

-метод ближайшего соседа

-метод опорных векторов

Статистические методы – основаны на вычислении вероятности принадлежности классу


-Байесовский классификатор

Нейронные сети

Обучение по подобию - ты то, на что похож


Объект = вектор признаков (точка в пространстве признаков)

Задача построить решающую функцию, которая по заданному вектору давала ответ кому принадлежит объект




Обучение по подобию: методы ближайших соседей

Метод ближайших соседей — объект относится к тому классу, которому принадлежат ближайшие к нему объекты обучающей выборки.




Метод k-ближайших соседей - классифицируется путем нахождения k-ближайших соседей, которые после этого голосуют.



Обучение по подобию: метод опорных векторов



Метод опорных векторов – выбирается плоскость, которая максимизирует зазор м/ду наборами данных.




Статистические методы: Байесовский классификатор

$$P(\text{класс } A \mid \text{Признак 1, Признак 2 } \dots) = \frac{P(\text{Признак 1} \mid \text{Класс } A)P(\text{Признак 2} \mid \text{Класс } A) \dots P(\text{класс } A)}{P(\text{Признак 1})P(\text{Признак 2})}$$


Модель нейрона (Перцептрон)



Многослойные нейронные сети




Алгоритм обратного распространения ошибки




Точность классификации на G-окрашенных изображениях


Mehdi, Setarehdan, 2008; Lerner, 1995



Точность классификации на MFISH изображениях



Краткая история Нейронных сетей



Марвин Минский и Сеймур
Пейперт

Что изменилось с 90-х годов?



Что изменилось ?



Масштаб



Увеличились вычислительные мощности



Большое количество размеченных данных

Нейронные сети – возвращение



- базы данных аннотированных изображений

ImageNet Classification with Deep Convolutional Neural Networks

Alex Krizhevsky University of Toronto kriz@cs.utoronto.ca	Ilya Sutskever University of Toronto ilya@cs.utoronto.ca	Geoffrey E. Hinton University of Toronto hinton@cs.utoronto.ca
--	---	---


Abstract

We trained a large, deep convolutional neural network to classify the 1.2 million high-resolution images in the ImageNet LSVRC-2010 contest into the 1000 different classes. On the test data, we achieved top-1 and top-5 error rates of 37.5% and 17.0% which is considerably better than the previous state-of-the-art. The neural network, which has 60 million parameters and 650,000 neurons, consists of five convolutional layers, some of which are followed by max-pooling layers, and three fully-connected layers with a final 1000-way softmax. To make training faster, we used non-saturating neurons and a very efficient GPU implementation of the convolution operation. To reduce overfitting in the fully-connected layers we employed a recently-developed regularization method called “dropout” that proved to be very effective. We also entered a variant of this model in the ILSVRC-2012 competition and achieved a winning top-5 test error rate of 15.3%, compared to 26.2% achieved by the second-best entry.

С 2010 года ведётся проект ILSVRC (*ImageNet Large Scale Visual Recognition Challenge* — Кампания по широкомасштабному распознаванию образов в ImageNet) – Соревнование в классификации и распознавании объектов и сцен в базе данных ImageNet

В 2012 году победила нейронная сеть SuperVision

SuperVision



8 слоев, $650 \cdot 10^3$ нейронов, $60 \cdot 10^6$ характеристик, $630 \cdot 10^6$ связей

Распознавание лиц нейронными сетями

Labeled face in the wild – 13 000 фотографий



Точность распознавания



99.2%

Обрезанные изображения – 97.53%



Deepface - 97.35 (Taigman et al., 2014)



99.15 (Sun Y. et al., 2014)

<http://vis-www.cs.umass.edu/lfw/>

Huang G. B. et al. Labeled faces in the wild: A database for studying face recognition in unconstrained environments. – 2008.

Taigman Y. et al. Deepface: Closing the gap to human-level performance in face verification //Proceedings of the IEEE conference on computer vision and pattern recognition. – 2014

Sun Y., Wang X., Tang X. Deep learning face representation from predicting 10,000 classes //Proceedings of the IEEE conference on computer vision and pattern recognition. – 2014

Тенденция в машинном обучении

“

Мы не описываем алгоритм решения задачи и процедуру ее выполнения. Мы ставим задачу и предлагаем машине самой научиться ее решать.

”

Себрант А.Ю., директор по маркетингу
сервисов компании «Яндекс»

