

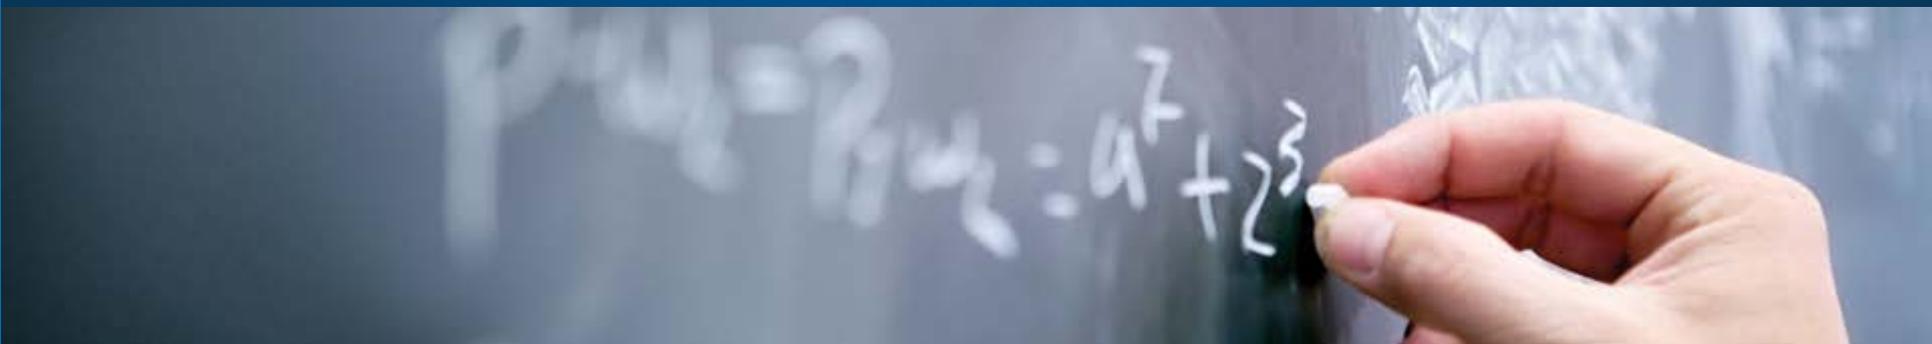
# Анализ изображений и видео

## Лекция 8: Сегментация изображений

Наталья Васильева

[nvassilieva@hp.com](mailto:nvassilieva@hp.com)

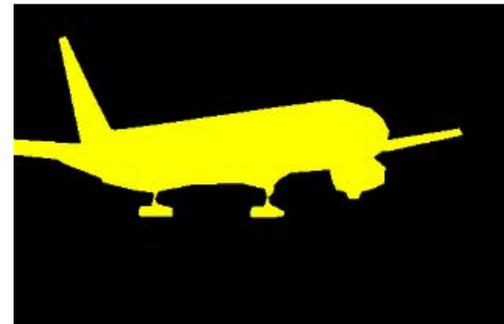
HP Labs Russia

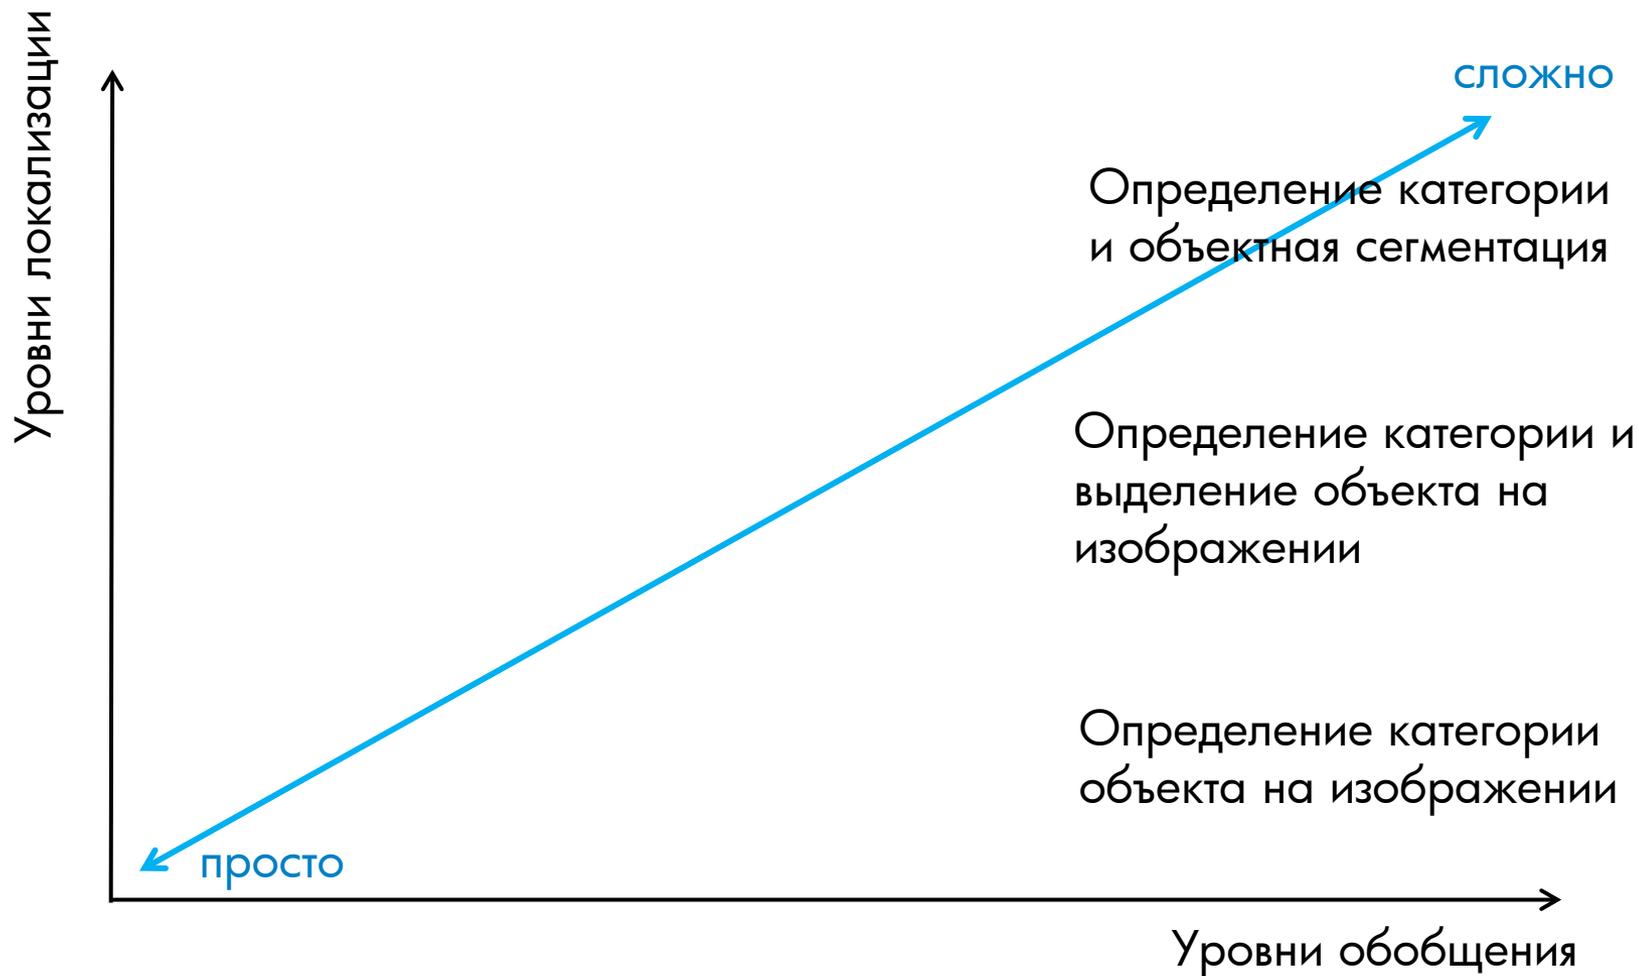


# Что есть распознанный объект?

## Разные уровни локализации

- Объект (сцена) присутствует на изображении  
классификация, категоризация изображений (image classification)
- Известно местоположение объекта, объект выделен на изображении  
обнаружение, выделение, локализация объекта (object detection, localization)
- Известны пиксели, принадлежащие объекту  
объектная сегментация (object segmentation)





# Что такое сегментация?

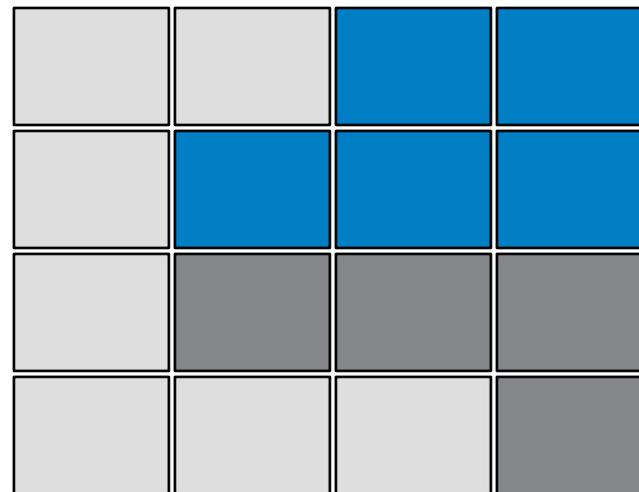
Деление изображения на составляющие его области или объекты

Объединение пикселей в группы по признаку «однородности», «связности»

Сегменты:

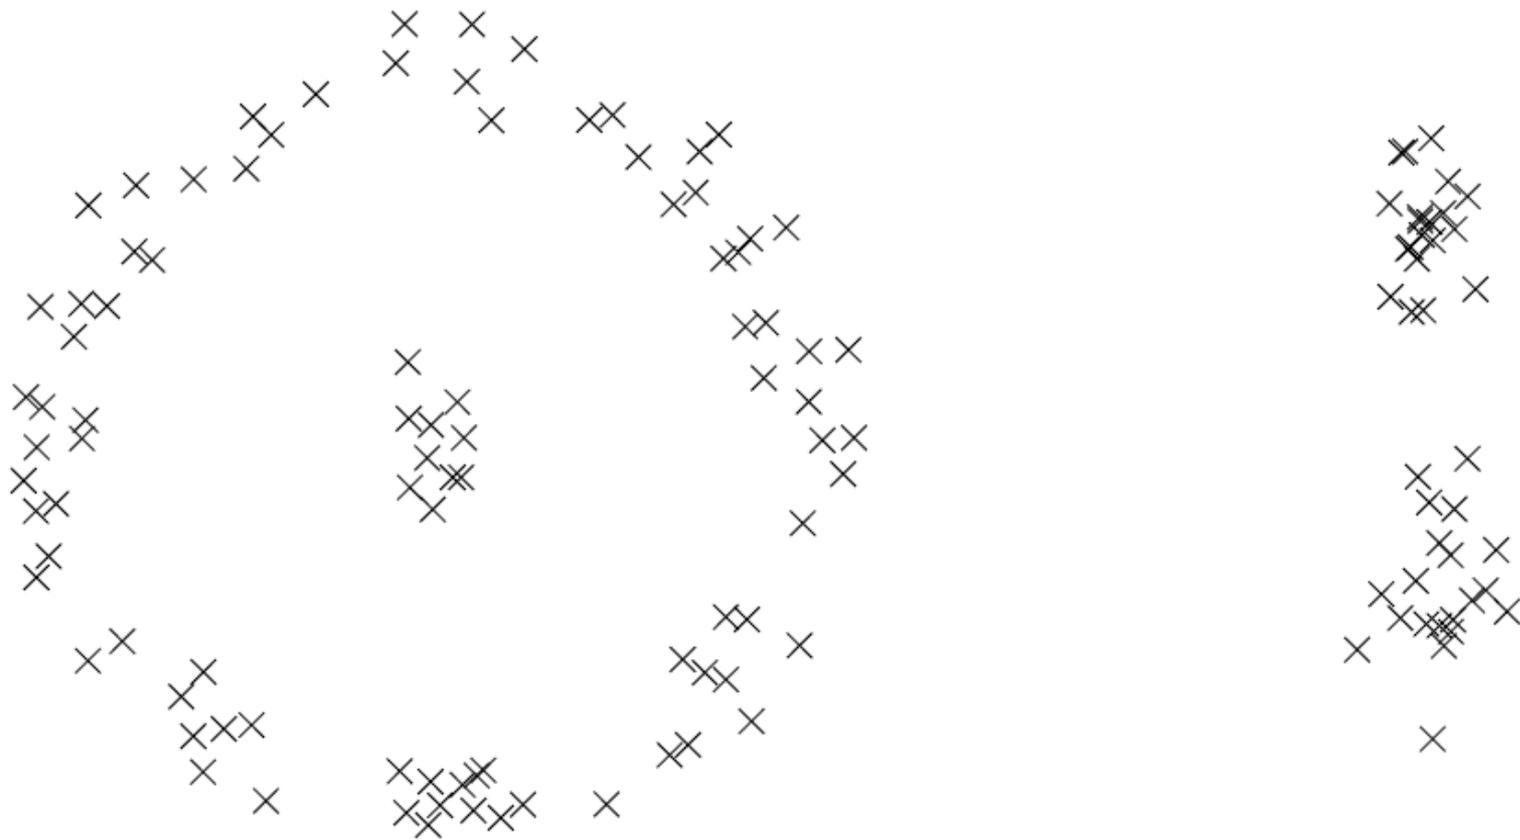


Пиксели, принадлежащие одному сегменту, «имеют что-то общее»

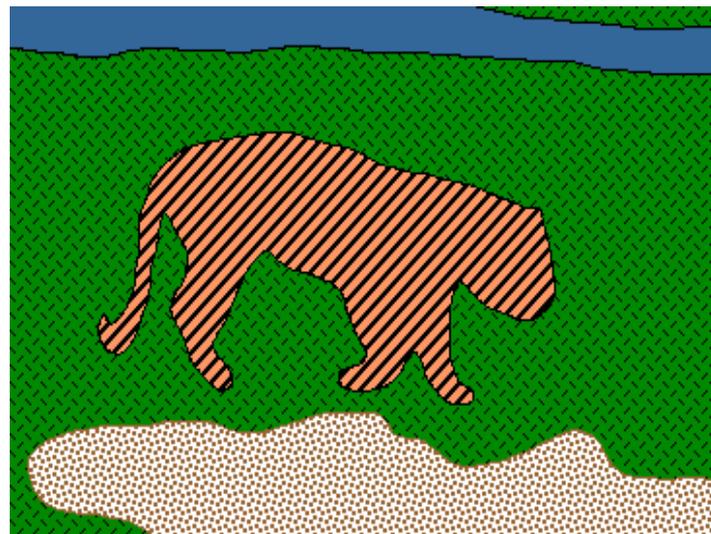


Сегментация – одна из самых сложных задач компьютерного зрения

# Что такое сегментация?



# Что такое сегментация?



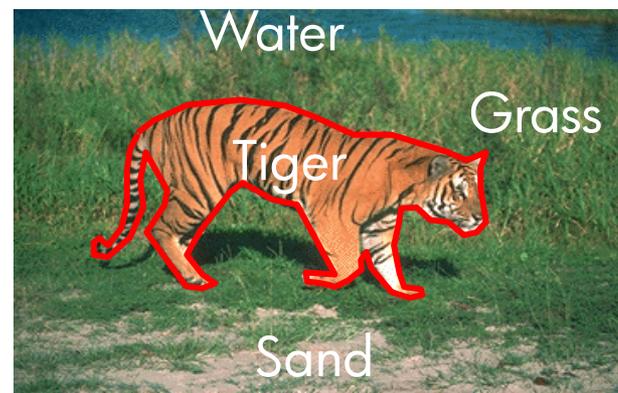
# Где используется сегментация?

Сегментация  
медицинских  
снимков



Сегментация  
аэрокосмических  
снимков

Выделение объектов на  
произвольных  
изображениях и видео

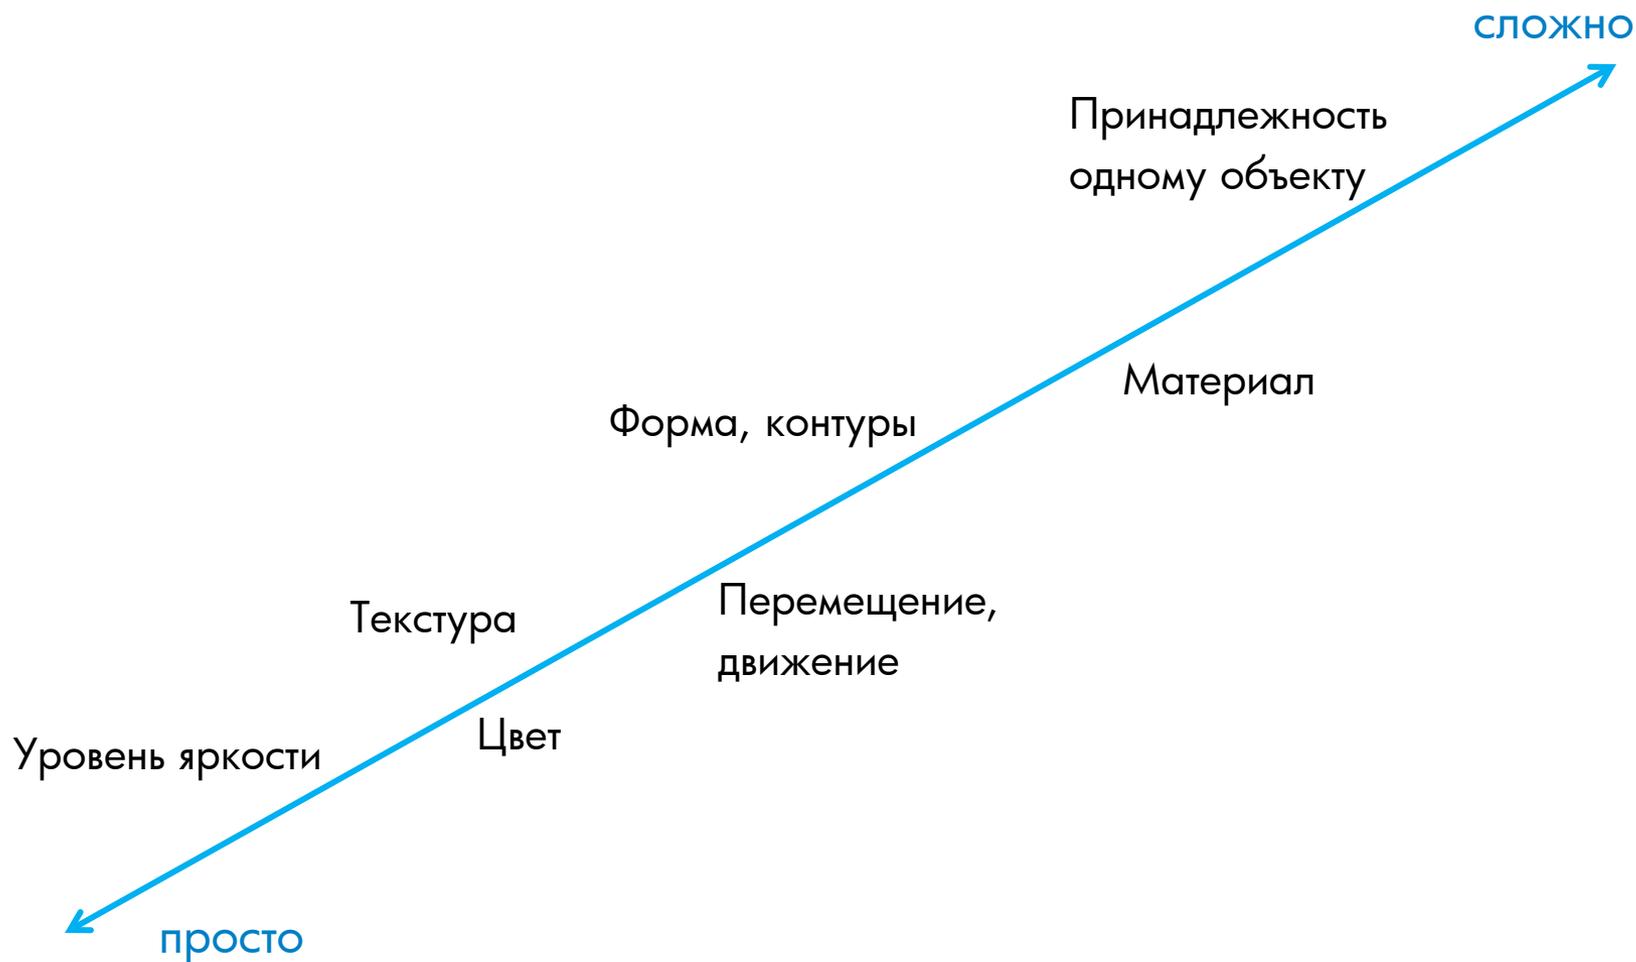


# Подзадачи сегментации

- Как определить, что значит «пиксели имеют что-то общее»?  
Что есть это «общее»?
- Как построить математическую модель, отражающую необходимое нам понимание «общности»?
- Как найти решения в выбранной модели?

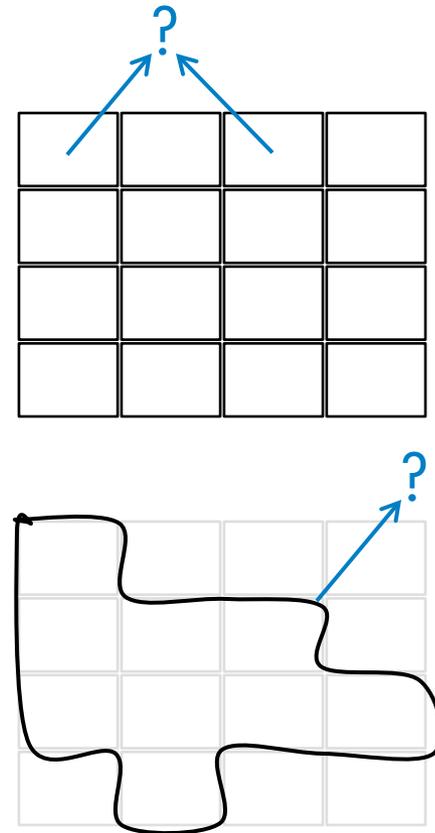


# Возможные критерии «общности»



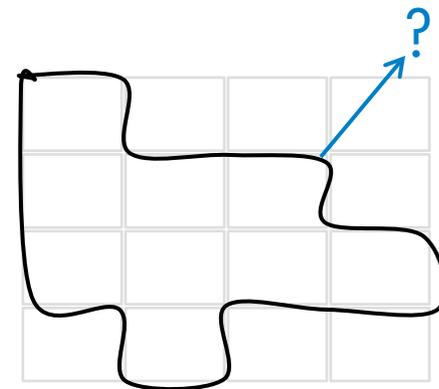
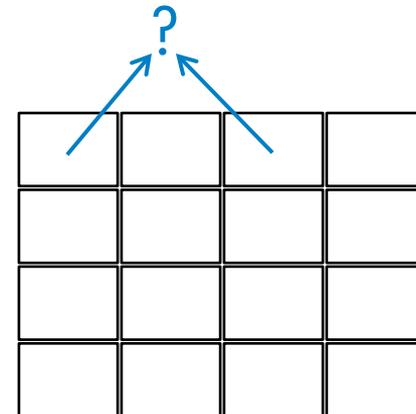
# Таксономия методов сегментации

- «Снизу-вверх» v.s. «сверху-вниз»
  - Bottom-up v.s. top-down
  - Pixel-based v.s. region-based/area-based
  - Local v.s. global
  - Feature-space based v.s. image-domain based
  - Region-based v.s. edge-based
- «Снизу-вверх»
  - Оцениваем «общность» отдельных пикселей или небольших групп пикселей
- «Сверху-вниз»
  - Оцениваем «общность» на глобальном уровне для всего сегмента



# Таксономия методов сегментации

- «Снизу-вверх» v.s. «сверху-вниз»
  - Bottom-up v.s. top-down
  - Pixel-based v.s. region-based/area-based
  - Local v.s. global
  - Feature-space based v.s. image-domain based
  - Region-based v.s. edge-based
- Автоматическая v.s. с учителем
  - Automated v.s. user-directed

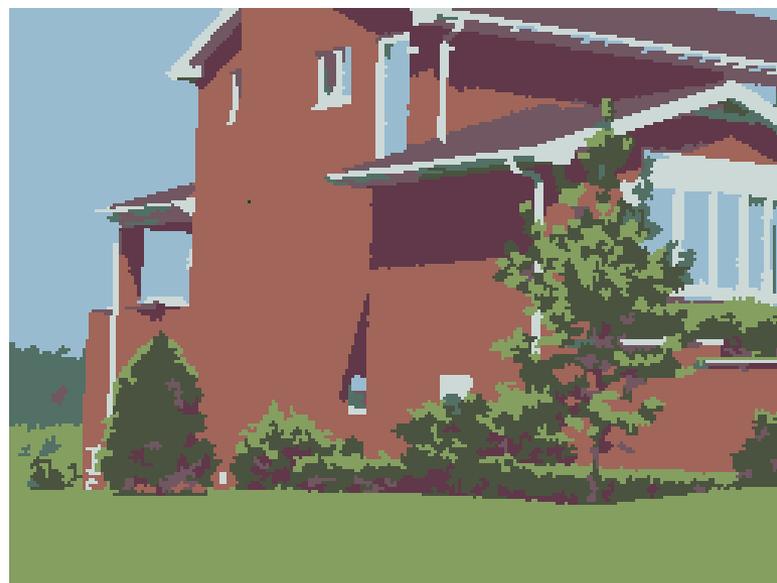


# Критерии «общности»

Цвет



255x192, 9603 цветов



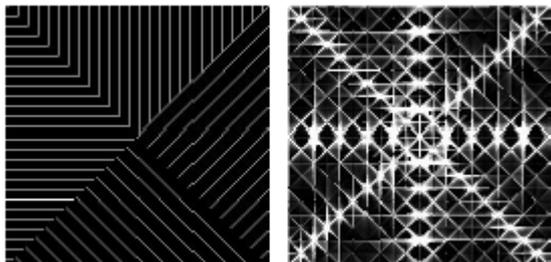
255x192, 8 цветов

D. Comaniciu, P. Meer: Robust Analysis of Feature Spaces: Color Image Segmentation, CVPR'97

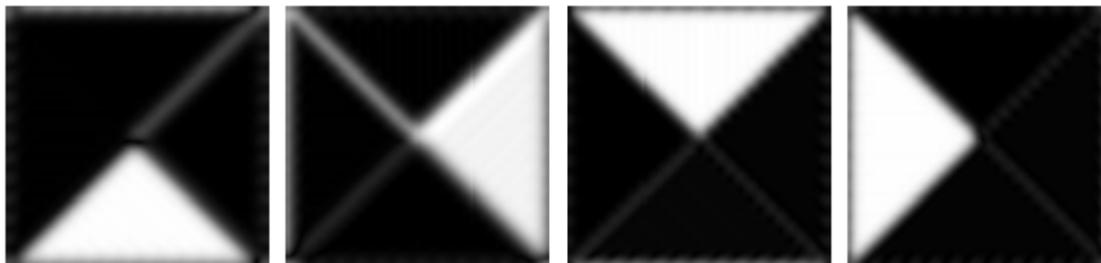


# Критерии «общности»

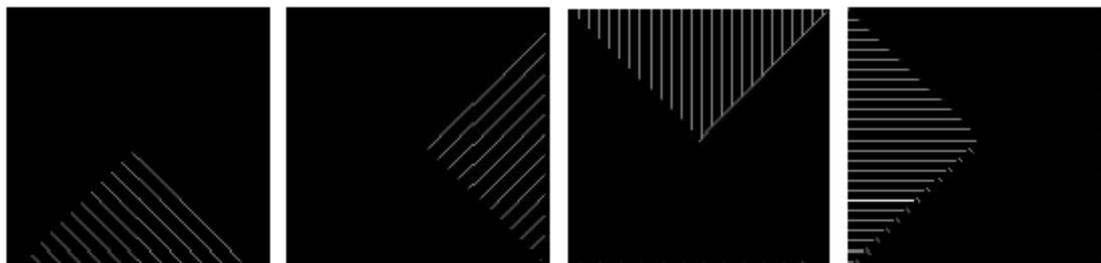
## Текстура



Исходное изображение и его Фурье-спектр



Амплитуды результатов свертки с 4 разными фильтрами Габора



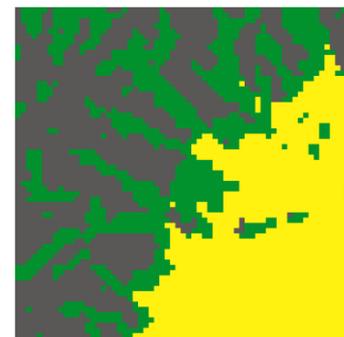
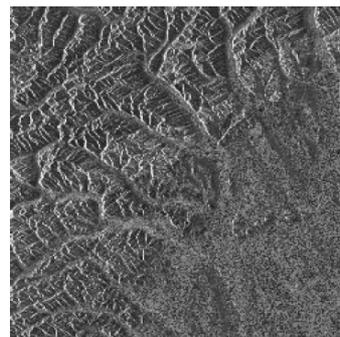
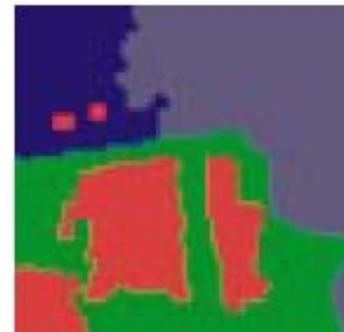
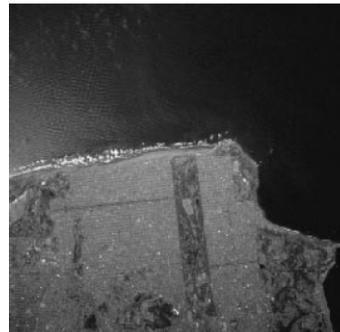
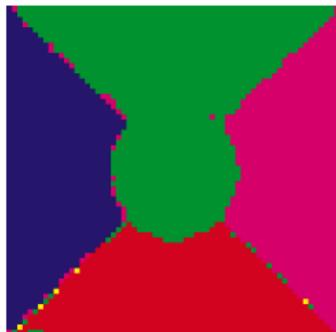
Результат сегментации

Vincent Levesque, Texture Segmentation Using Gabor Filters  
[http://www.cs.huji.ac.il/~simonp/papers/ip\\_project.pdf](http://www.cs.huji.ac.il/~simonp/papers/ip_project.pdf)



# Критерии «общности»

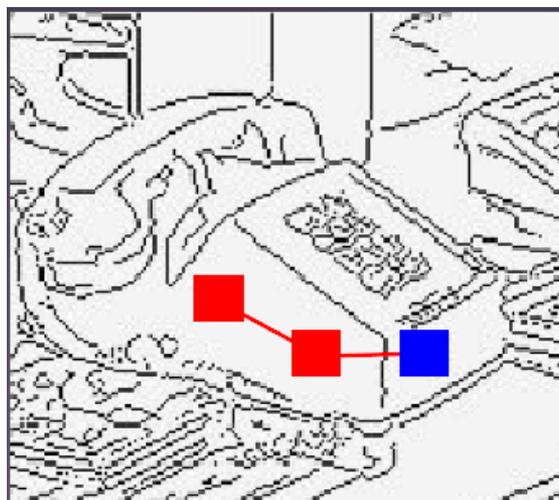
## Текстура



Thomas Hofmann, Jan Puzicha, Joachim M. Buhmann, Deterministic annealing for unsupervised texture segmentation, EMCCVPR '97, pp. 213-228

# Критерии «общности»

Расположение относительно контура



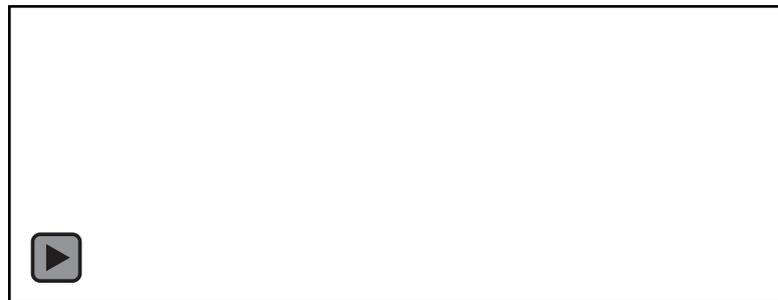
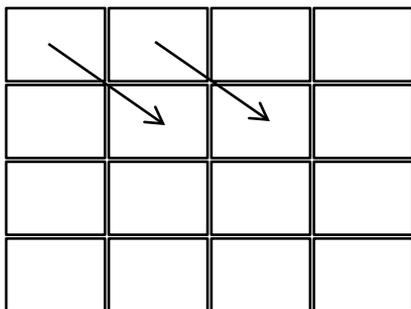
Stella Yu, PhD thesis, 2003



# Критерии «общности»

Перемещение, движение (motion)

Одинаковые параметры векторов перемещения: направление, длина

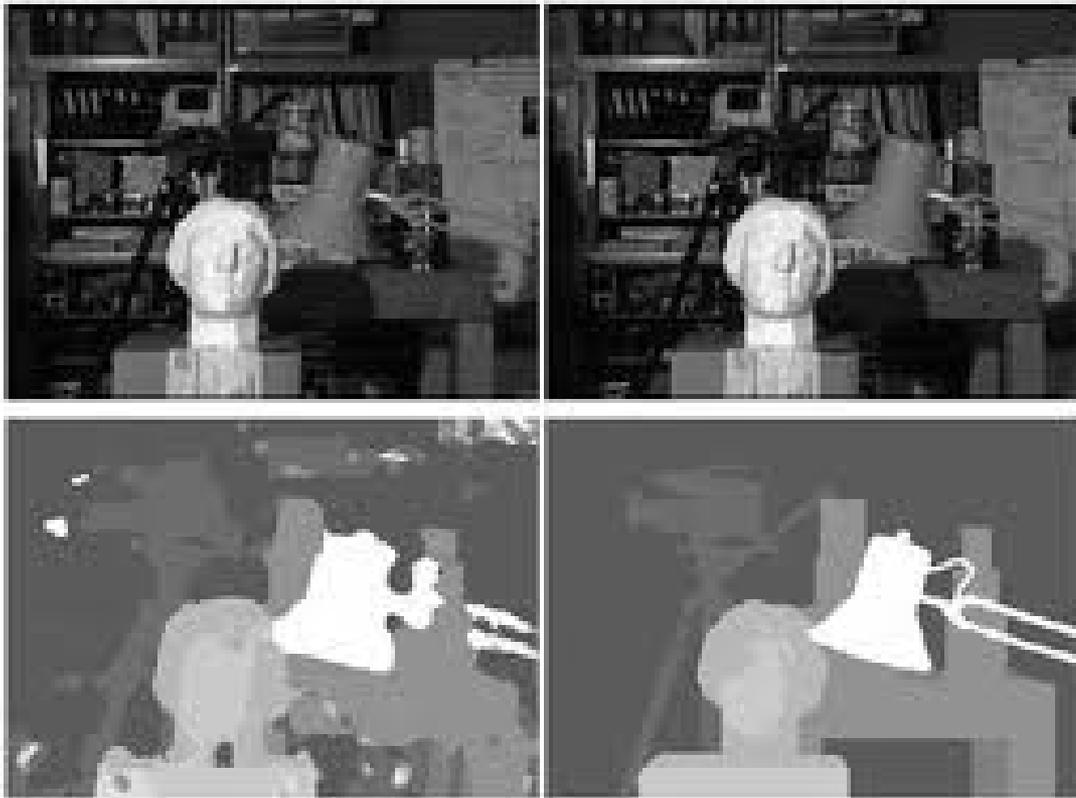


<http://www.svcl.ucsd.edu/projects/motiondytex/demo.htm>

[http://vcla.stat.ucla.edu/old/Barbu\\_Research/Motion\\_estim/index.html](http://vcla.stat.ucla.edu/old/Barbu_Research/Motion_estim/index.html)

# Критерии «общности»

Глубина (depth)



M. Domínguez-Morales, A. Jiménez-Fernández, R. Paz-Vicente, A. Linares-Barranco and G. Jiménez-Moreno  
Stereo Matching: From the Basis to Neuromorphic Engineering



# Критерии «общности»

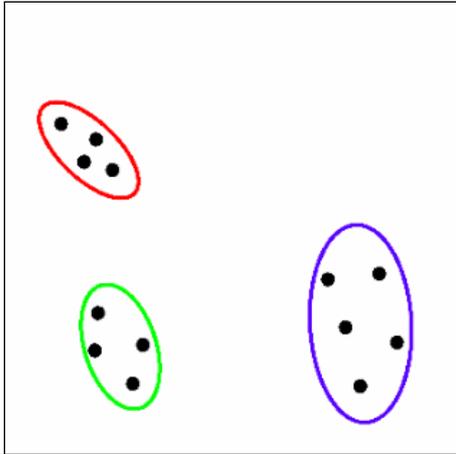
## Глобальные

- Расстояние между пикселями
  - Пиксели из одного сегмента расположены рядом
- Число сегментов
  - Семантически значимых сегментов не должно быть много на изображении
- Форма/контур сегмента
  - Контур сегмента не должен быть очень сложным

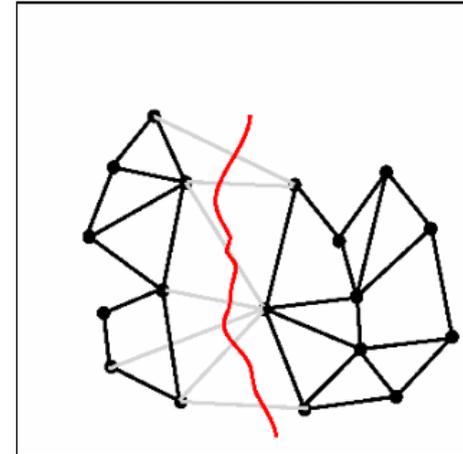


# Математические модели

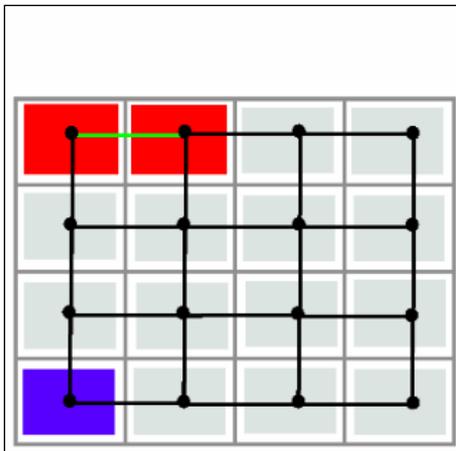
Кластеры в пространстве признаков



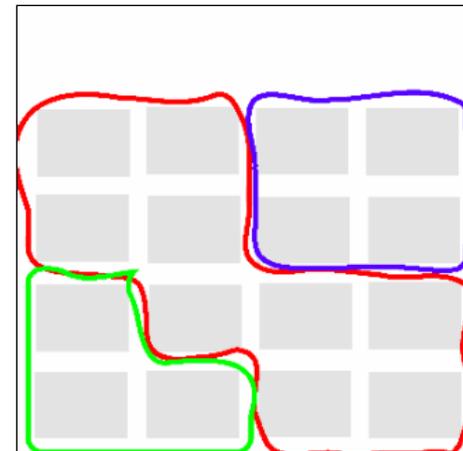
Полносвязный граф



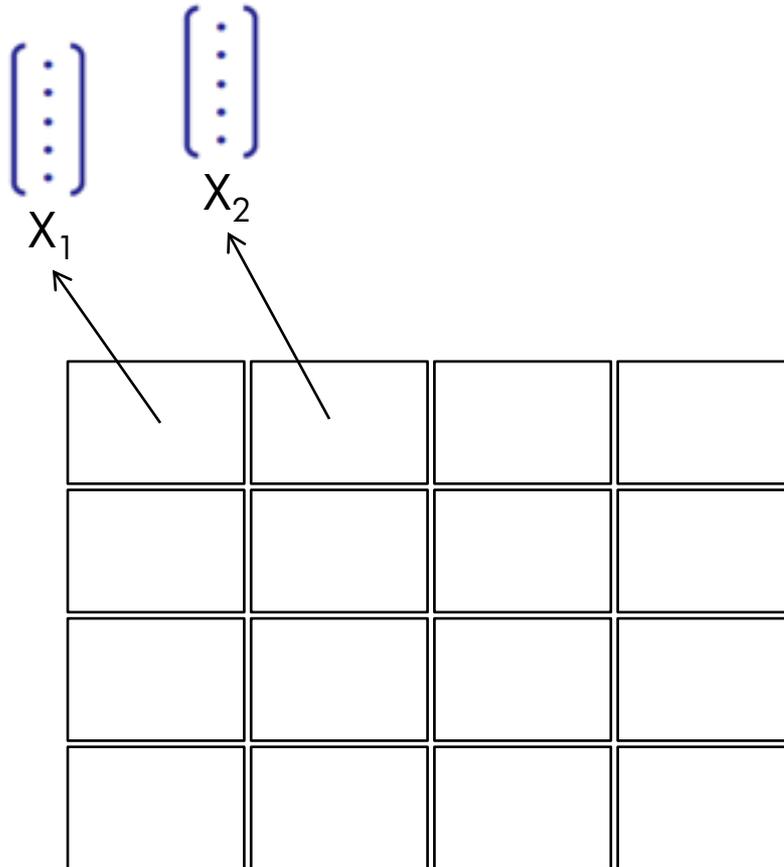
2-D решетка



Множество регионов



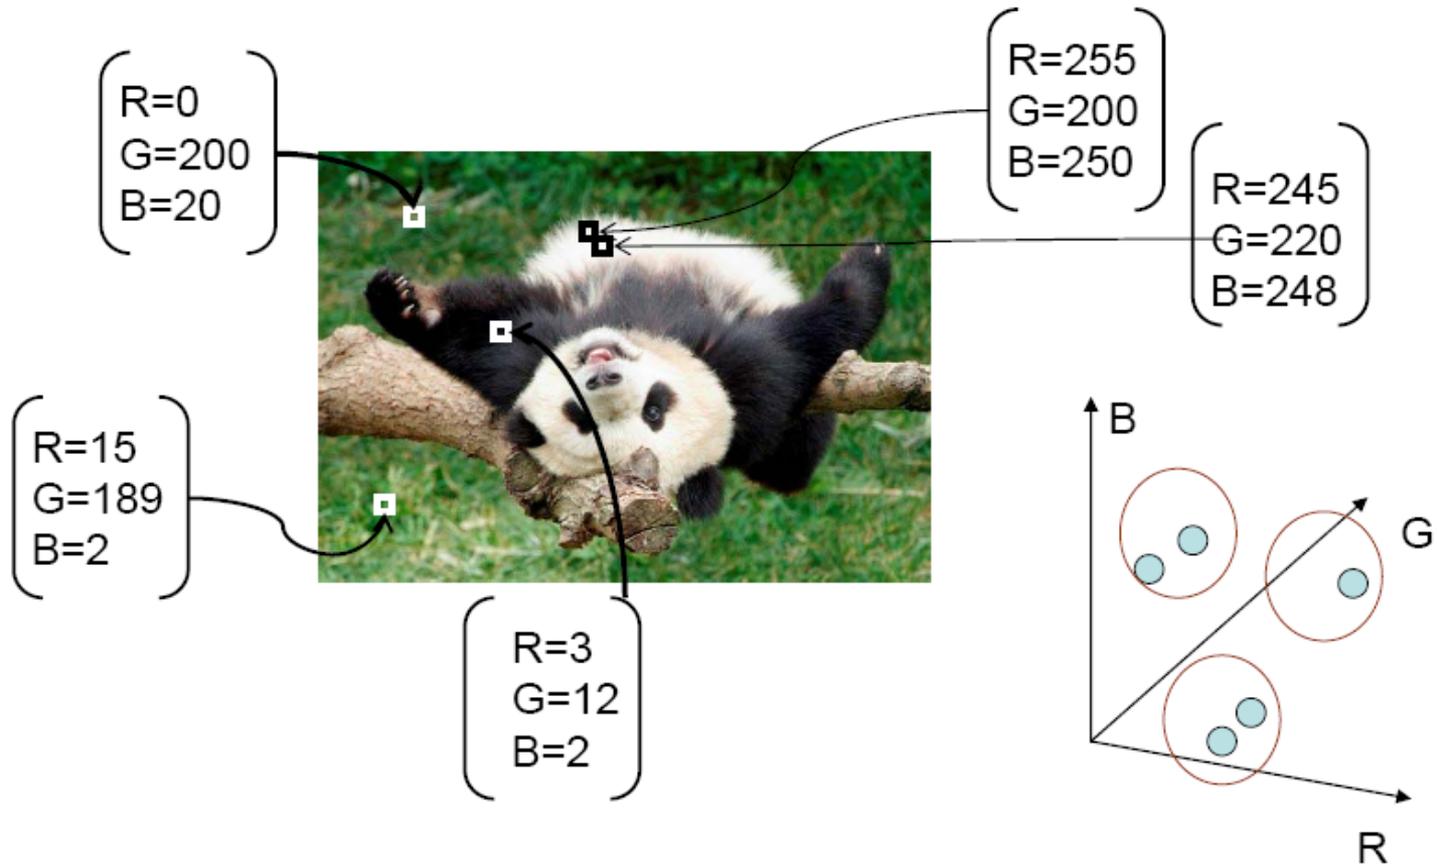
# Использование кластеризации



$X_1, X_2$  – вектора признаков  
(описывают цвет, текстуру,  
перемещение,...)

# Использование кластеризации

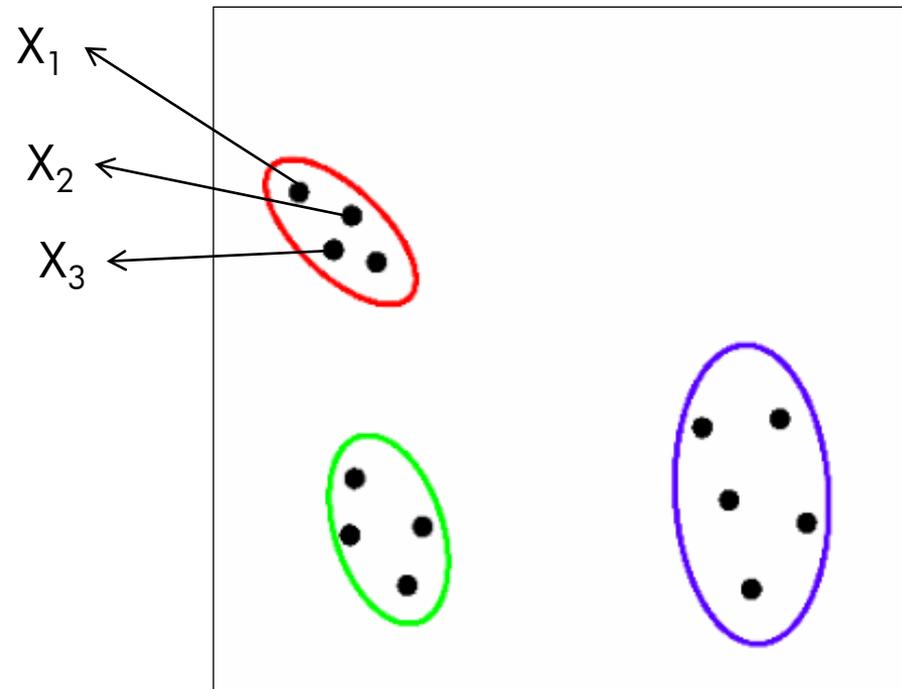
- Cluster similar pixels (features) together



# Кластеризация

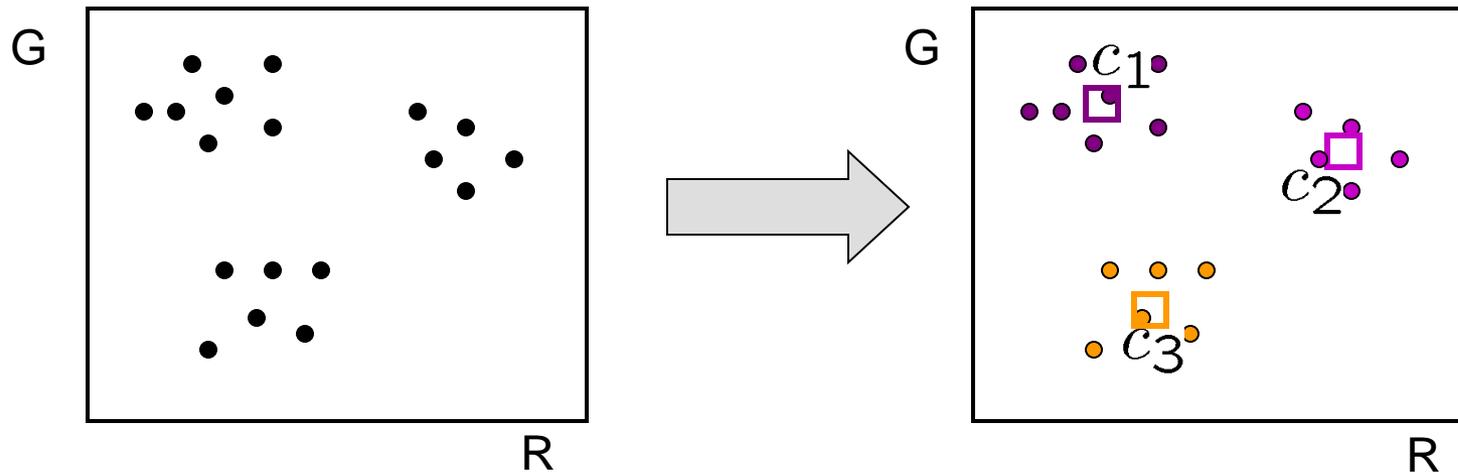
Вопросы:

- Какие признаки использовать?
- Как сравнивать вектора (какая метрика)?
- Сколько кластеров?
- Форма кластеров?



# Метод k-средних

## Основная идея



Каждая точка должна быть как можно ближе к центру своего кластера:

$$\sum_{\text{clusters } i} \sum_{\text{points } p \text{ in cluster } i} \|p - c_i\|^2 \longrightarrow \min$$

# Метод $k$ -средних (k-means)

## Алгоритм

1. Выбрать  $k$
2. Инициализировать  $k$  центров (например, случайным образом)
3. Распределить точки по кластерам: каждую точку присвоить к кластеру с ближайшим к точке центром
4. Переместить центры, чтобы они действительно были центрами получившихся кластеров
5. Если хотя бы один центр поменялся на шаге 4, перейти к шагу 3

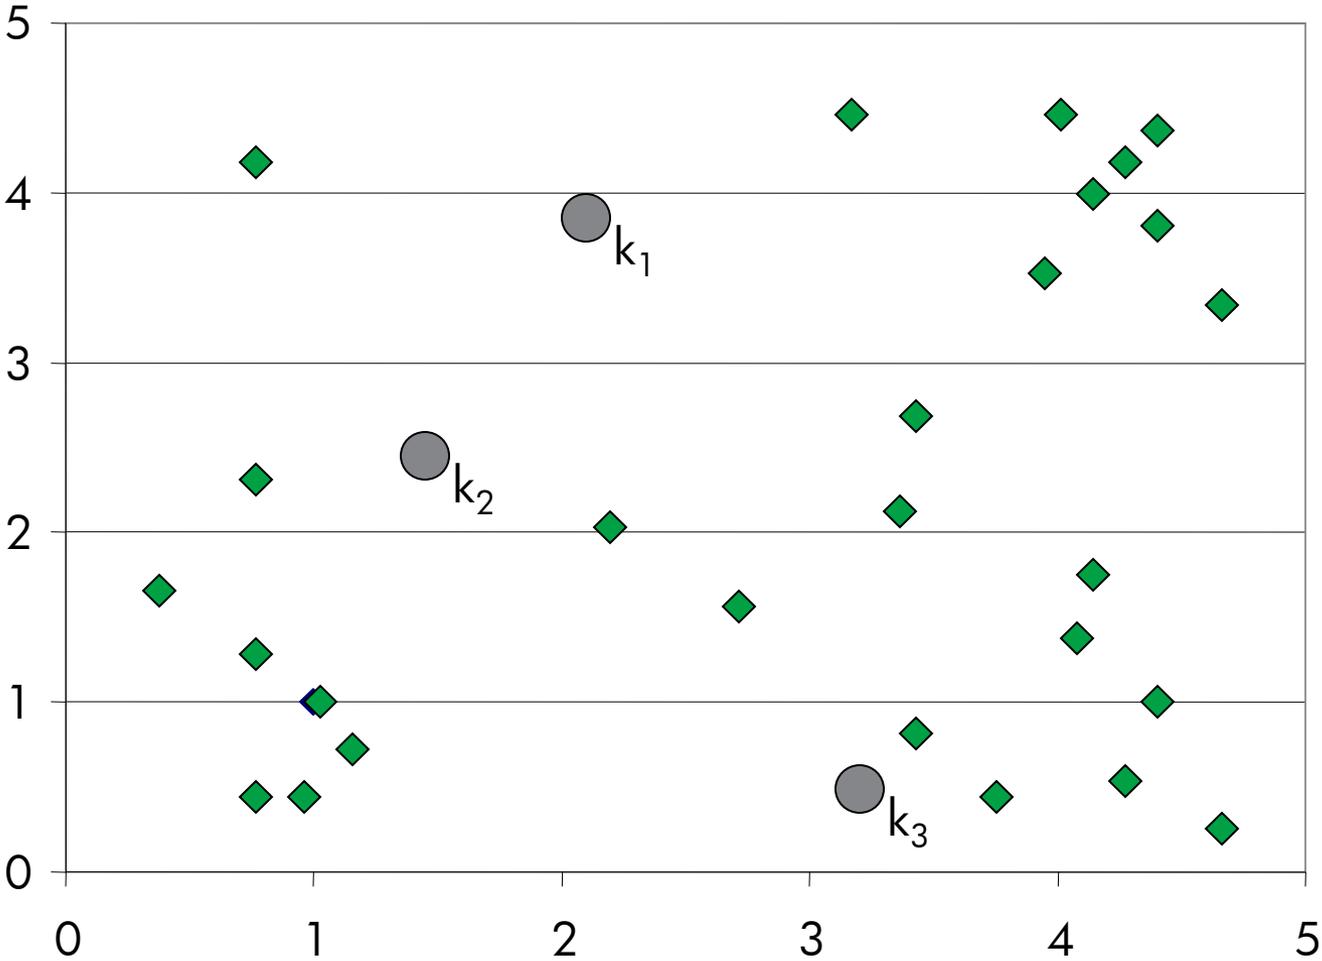
Java демо:

[http://home.dei.polimi.it/matteucc/Clustering/tutorial\\_html/AppletKM.html](http://home.dei.polimi.it/matteucc/Clustering/tutorial_html/AppletKM.html)



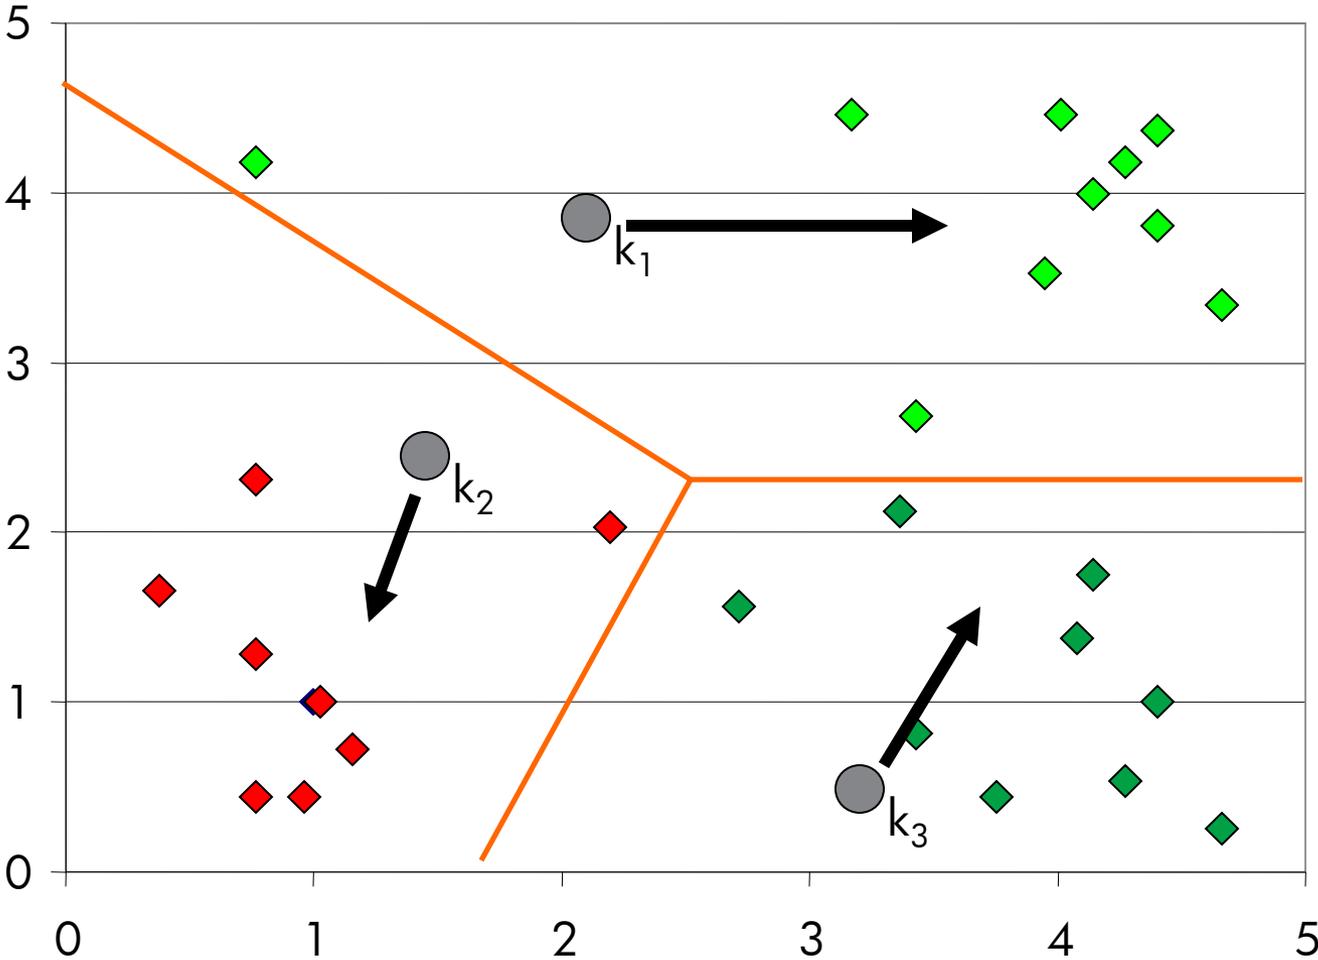
# Метод k-средних: шаг 1

Distance Metric: Euclidean Distance



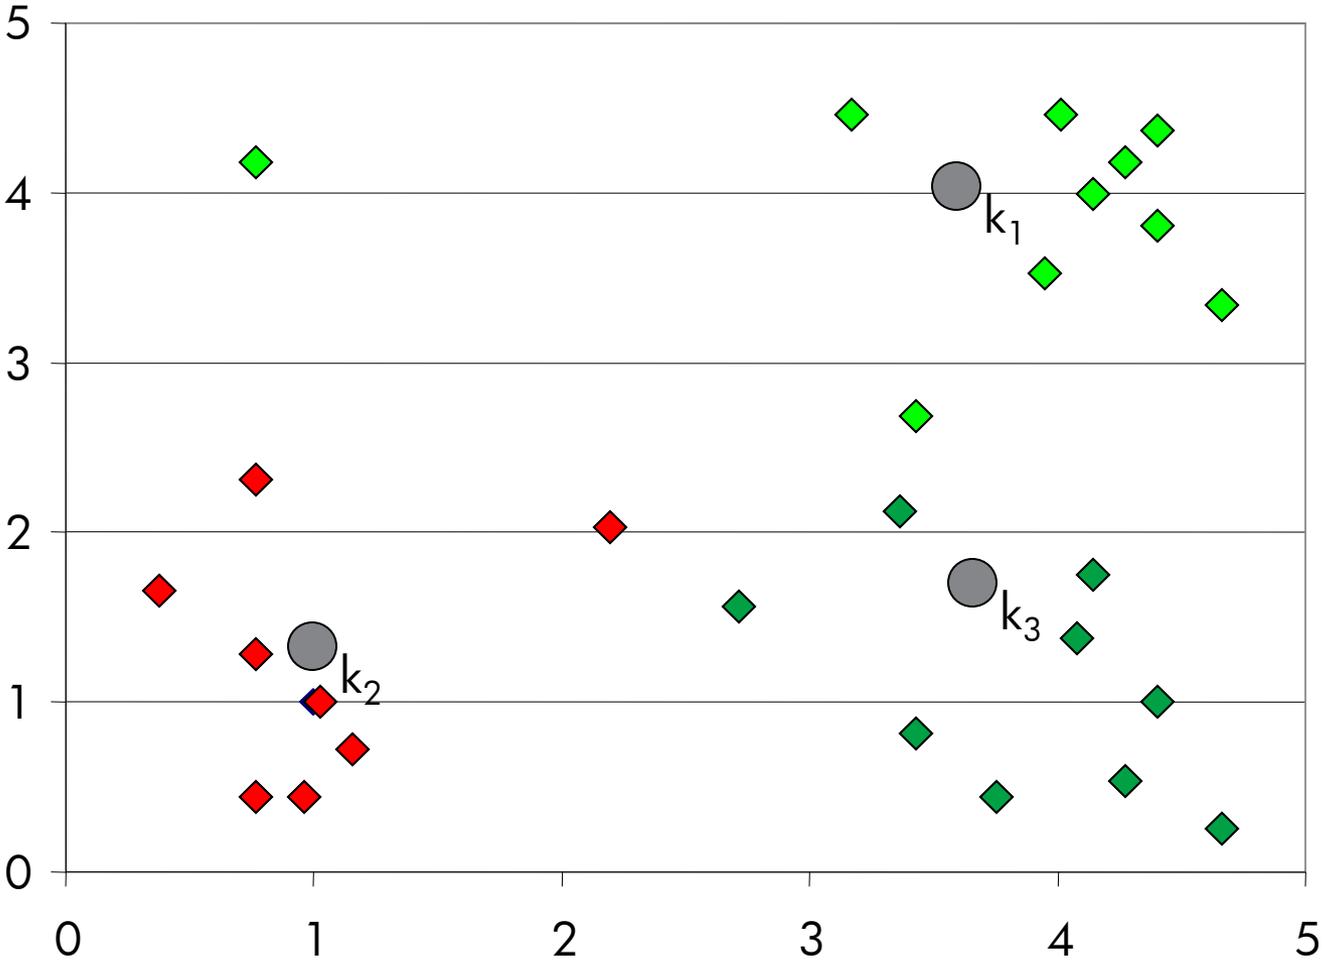
# Метод k-средних: шаг 2

Distance Metric: Euclidean Distance



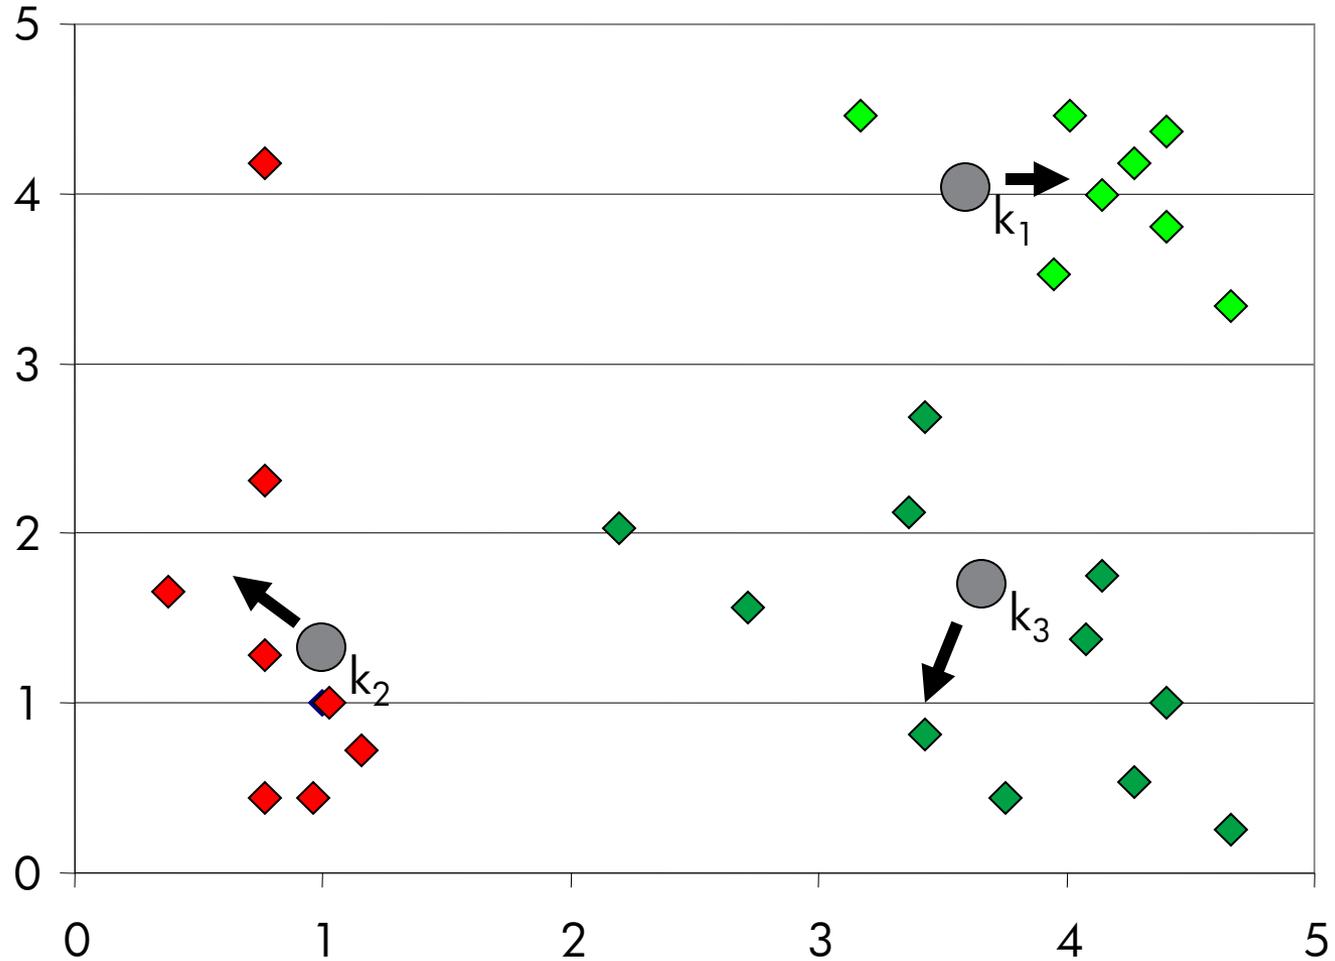
# Метод k-средних: шаг 3

Distance Metric: Euclidean Distance



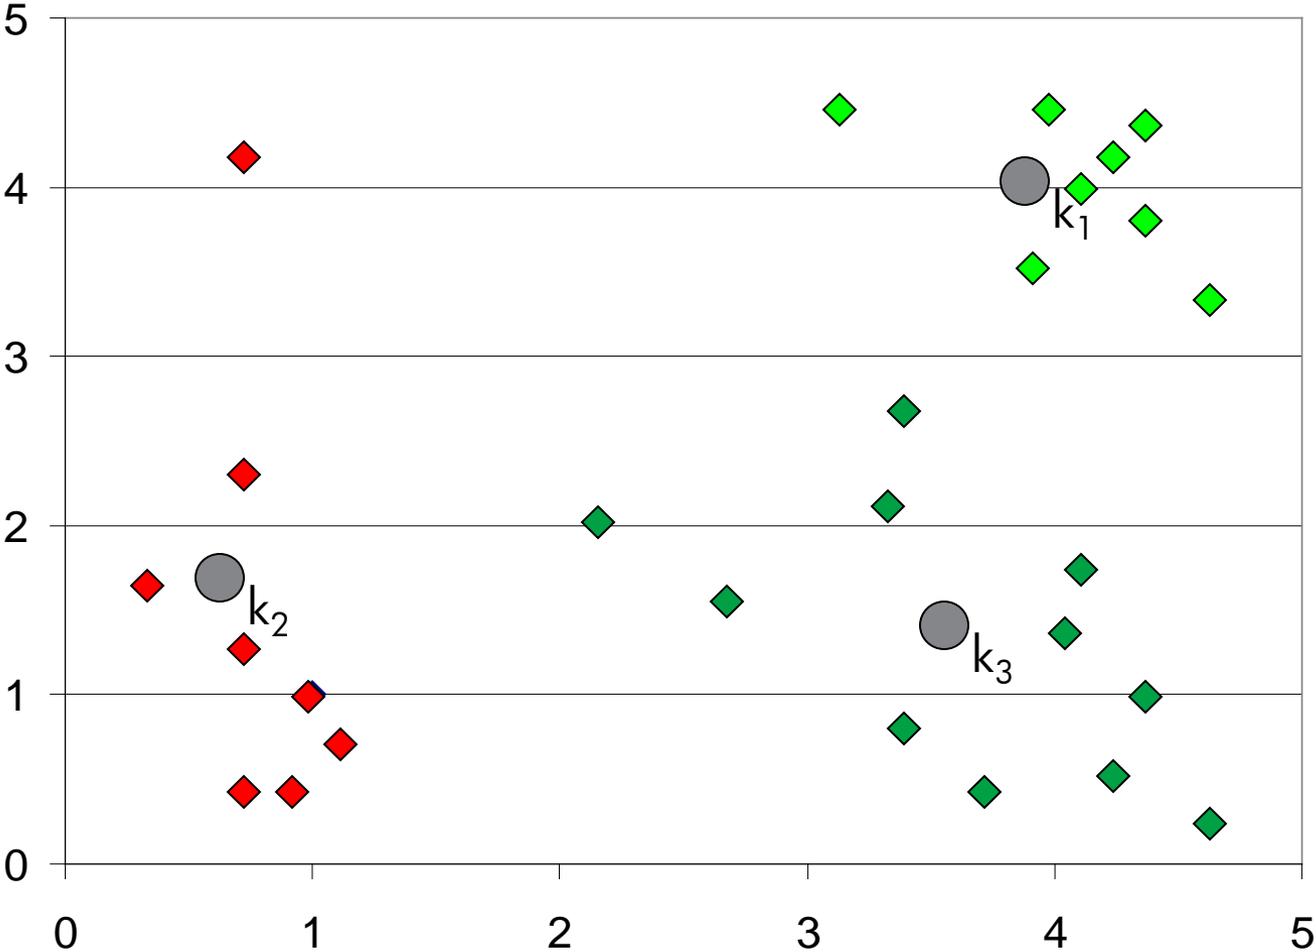
# Метод k-средних: шаг 4

Distance Metric: Euclidean Distance



# Метод k-средних: шаг 5

Distance Metric: Euclidean Distance



# Сегментация методом k-средних

- K-means clustering based on intensity or color is essentially vector quantization of the image attributes
- Clusters don't have to be spatially coherent

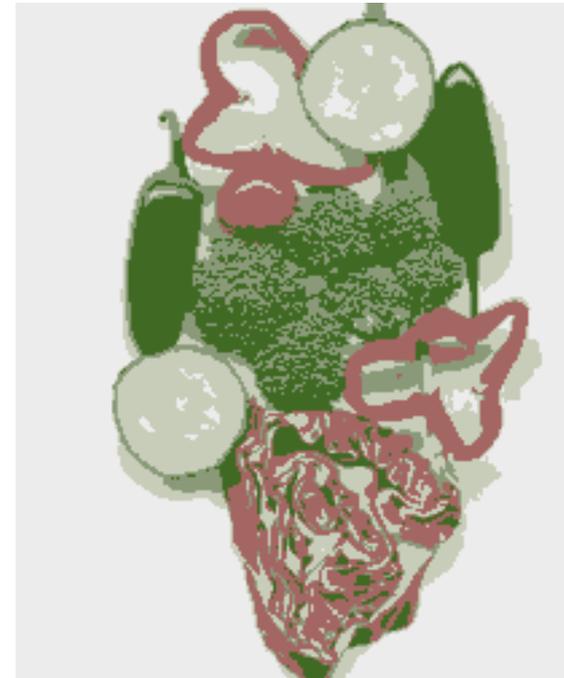
Image



Intensity-based clusters

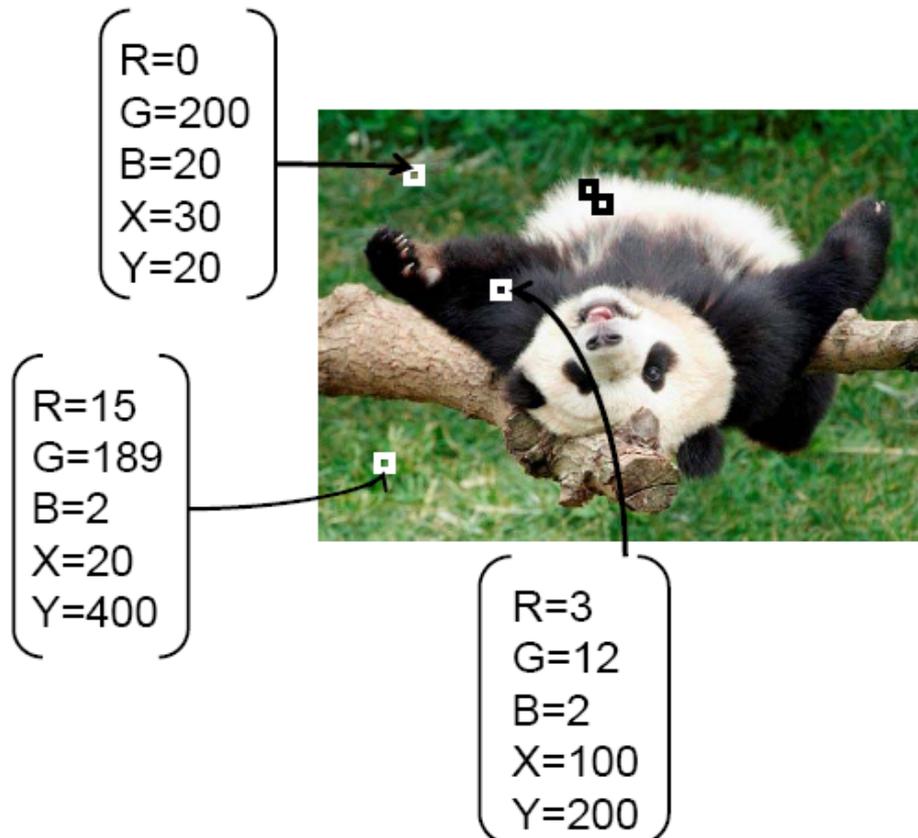


Color-based clusters



# Добавление пространственной информации

- Cluster similar pixels (features) together



...  
Distance based  
on color and  
position

Source: K. Grauman



# Сегментация методом k-средних

- Clustering based on  $(r, g, b, x, y)$  values enforces more spatial coherence



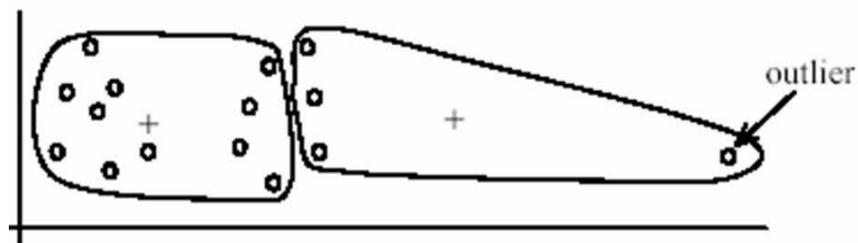
# k-Means: достоинства и недостатки

- Достоинства

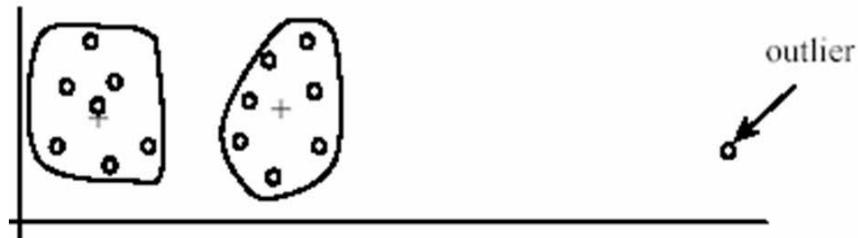
- Простота

- Недостатки

- Converges to a local minimum of the error function (решение: K-means++)
- Memory-intensive
- Need to pick K
- Sensitive to initialization
- Sensitive to outliers
- Only finds “spherical” clusters



(A): Undesirable clusters

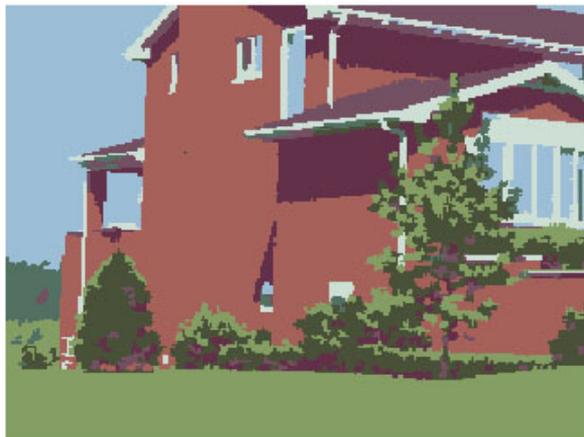


(B): Ideal clusters

# Mean-shift for image segmentation

Useful to take into account spatial information

- instead of  $(R, G, B)$ , run in  $(R, G, B, x, y)$  space
- D. Comaniciu, P. Meer, Mean shift analysis and applications, *7th International Conference on Computer Vision*, Kerkyra, Greece, September 1999, 1197-1203.
  - <http://www.caip.rutgers.edu/riul/research/papers/pdf/spatmsft.pdf>



More Examples: [http://www.caip.rutgers.edu/~comanici/segm\\_images.html](http://www.caip.rutgers.edu/~comanici/segm_images.html)

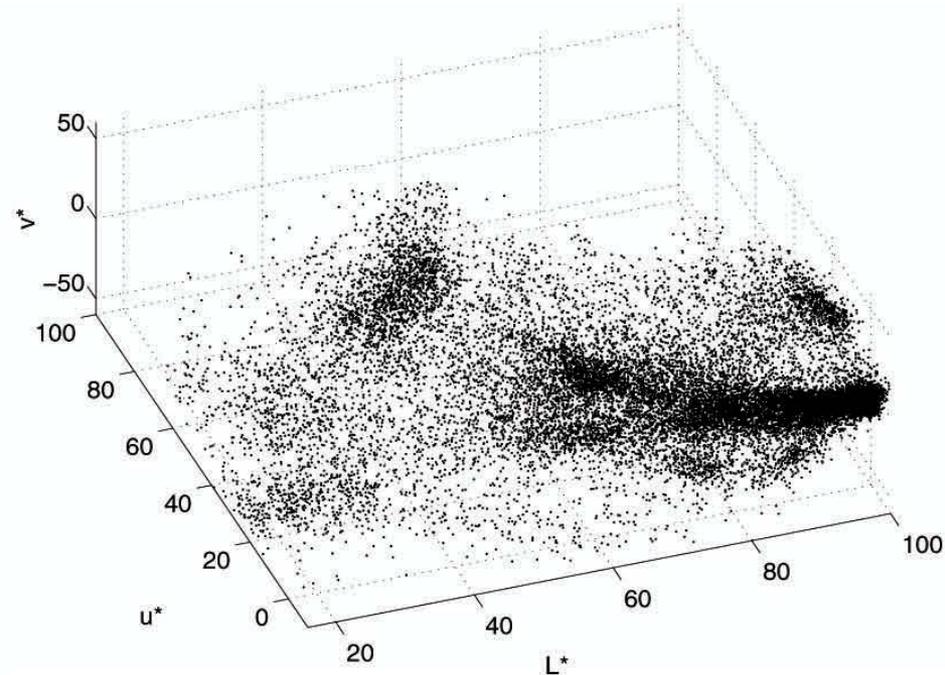
# Mean shift algorithm

The mean shift algorithm seeks *modes* or local maxima of density in the feature space

image

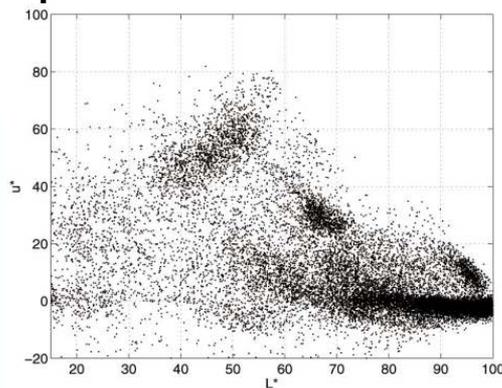


Feature space  
( $L^*u^*v^*$  color values)

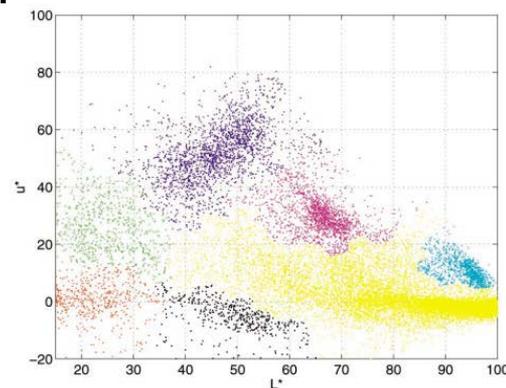


# Mean shift clustering/segmentation

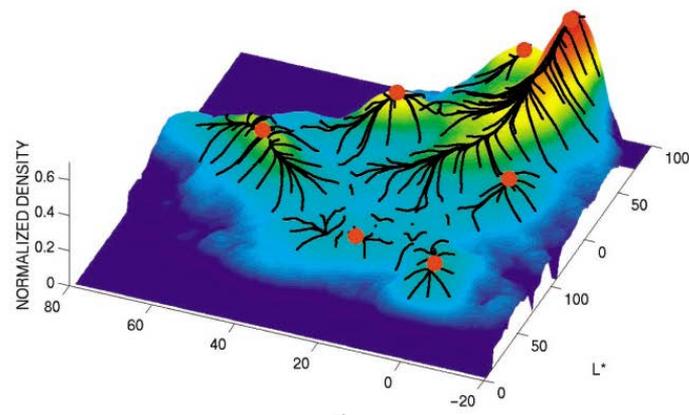
- Find features (color, gradients, texture, etc)
- Initialize windows at individual feature points
- Perform mean shift for each window until convergence
- Merge windows that end up near the same “peak” or mode



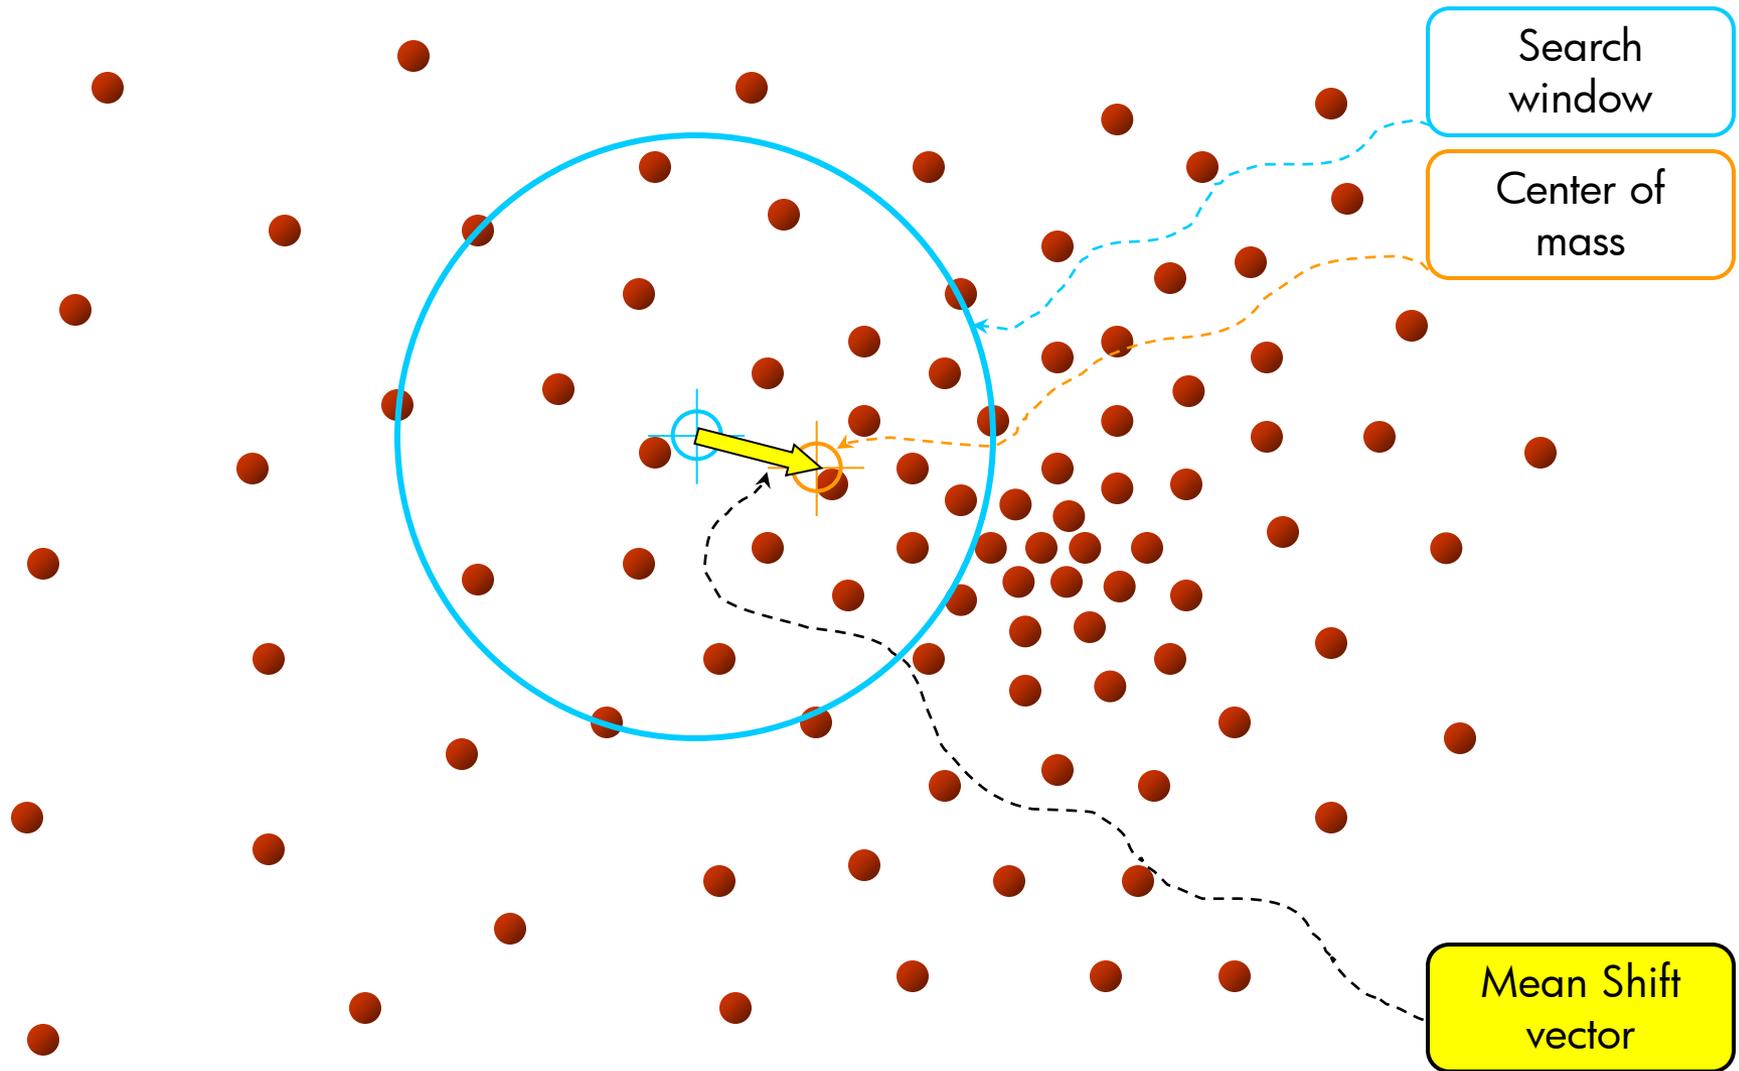
(a)



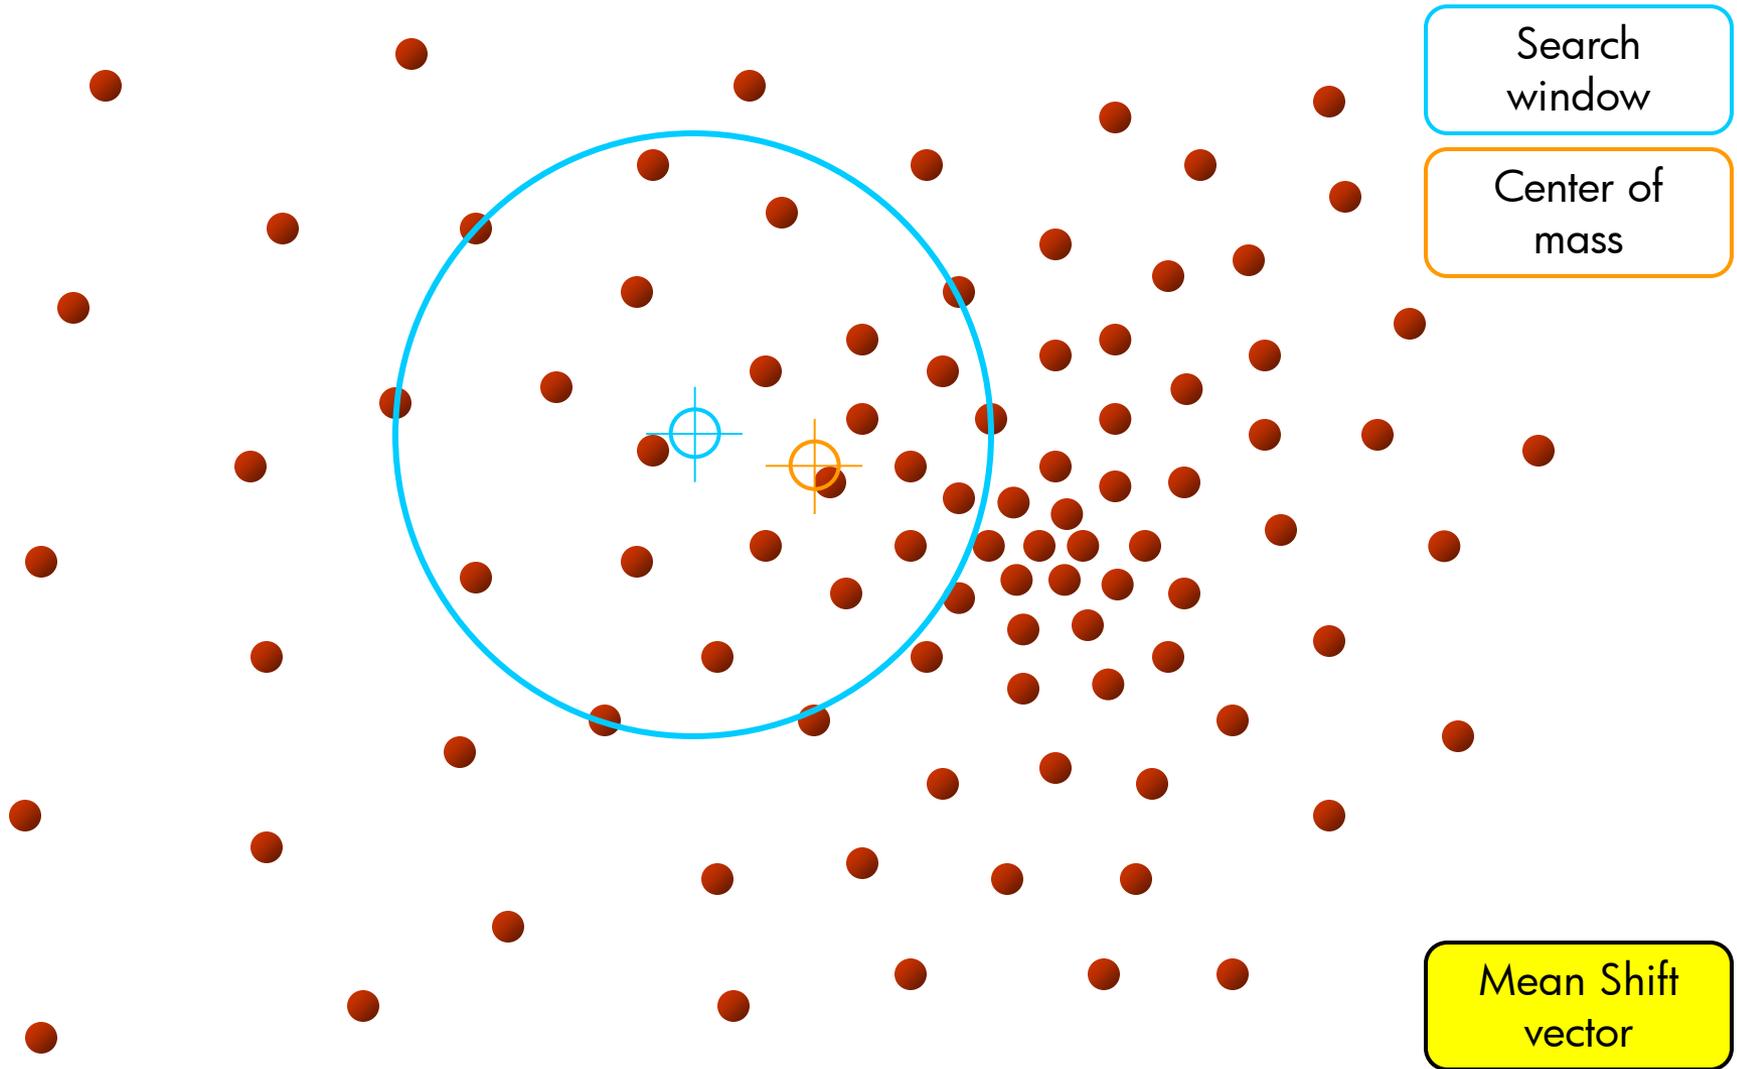
(b)



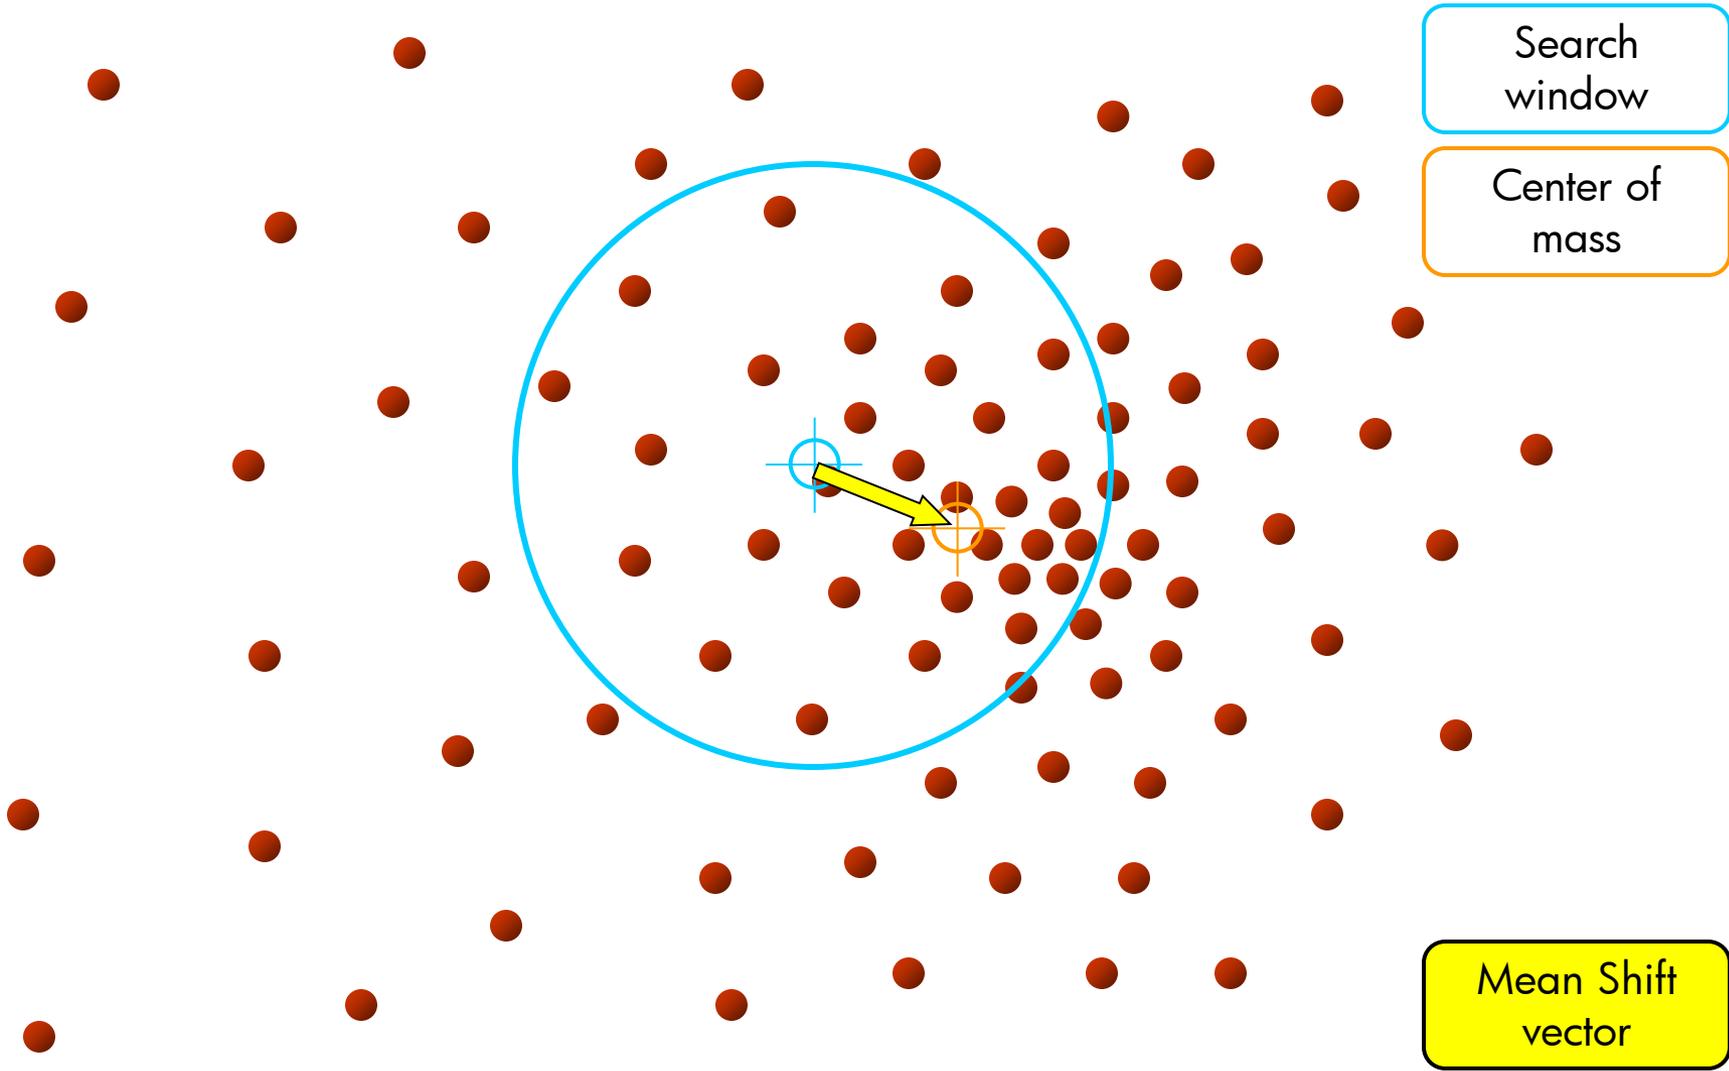
# Mean shift



# Mean shift



# Mean shift



Search window

Center of mass

Mean Shift vector

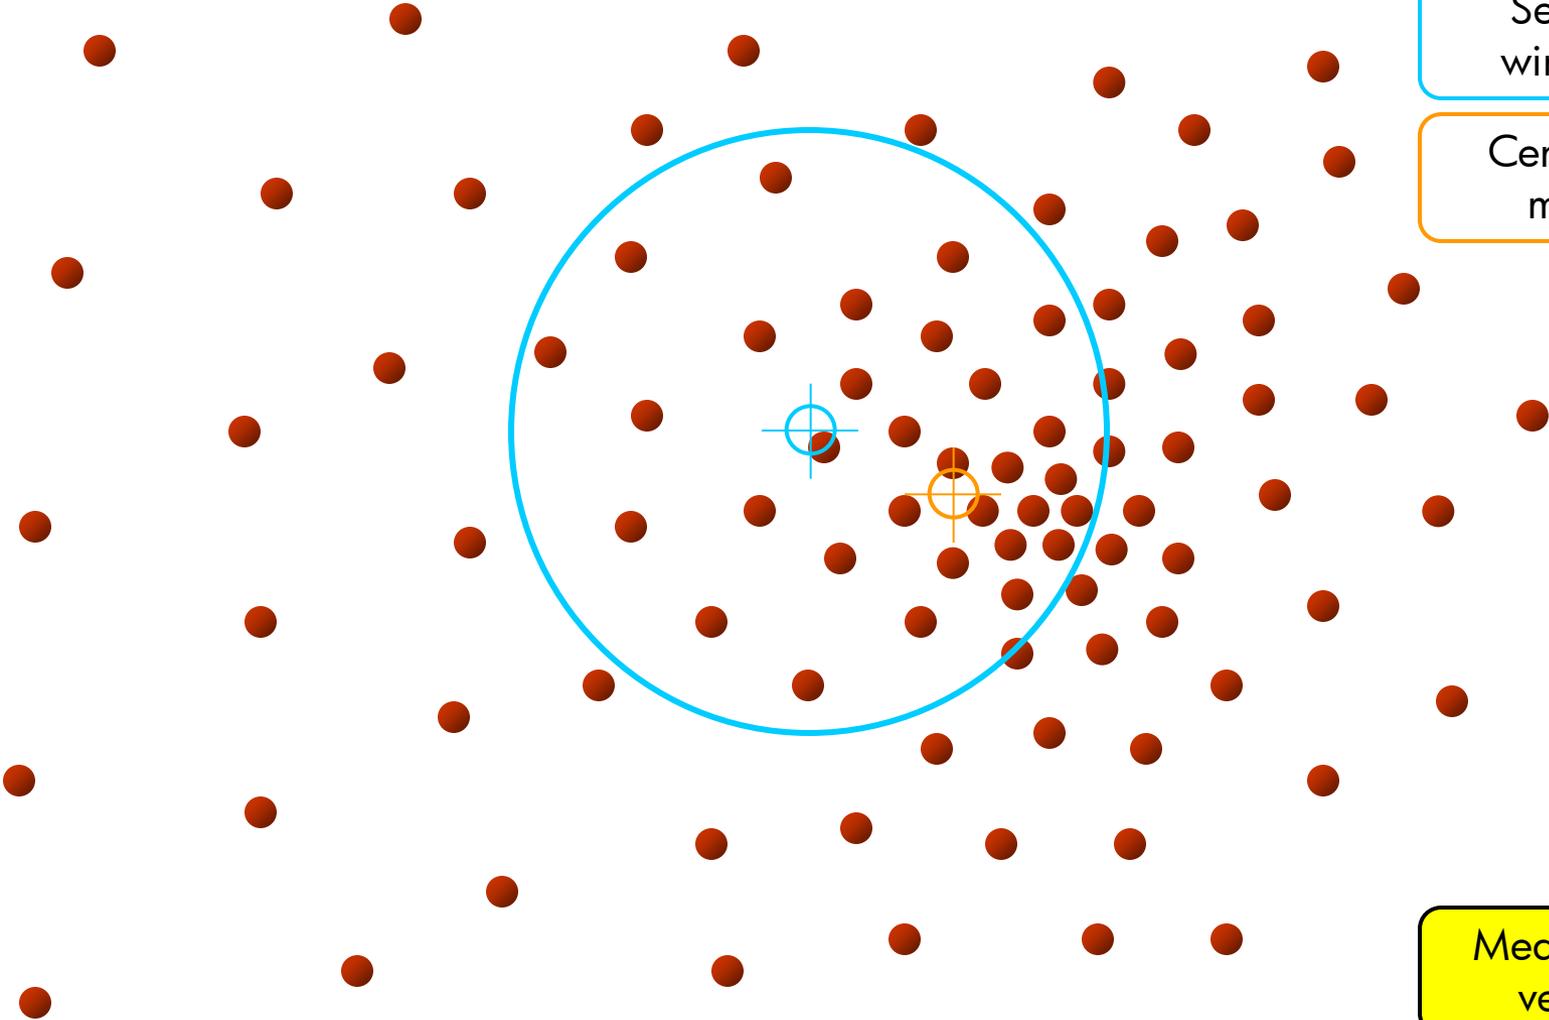


# Mean shift

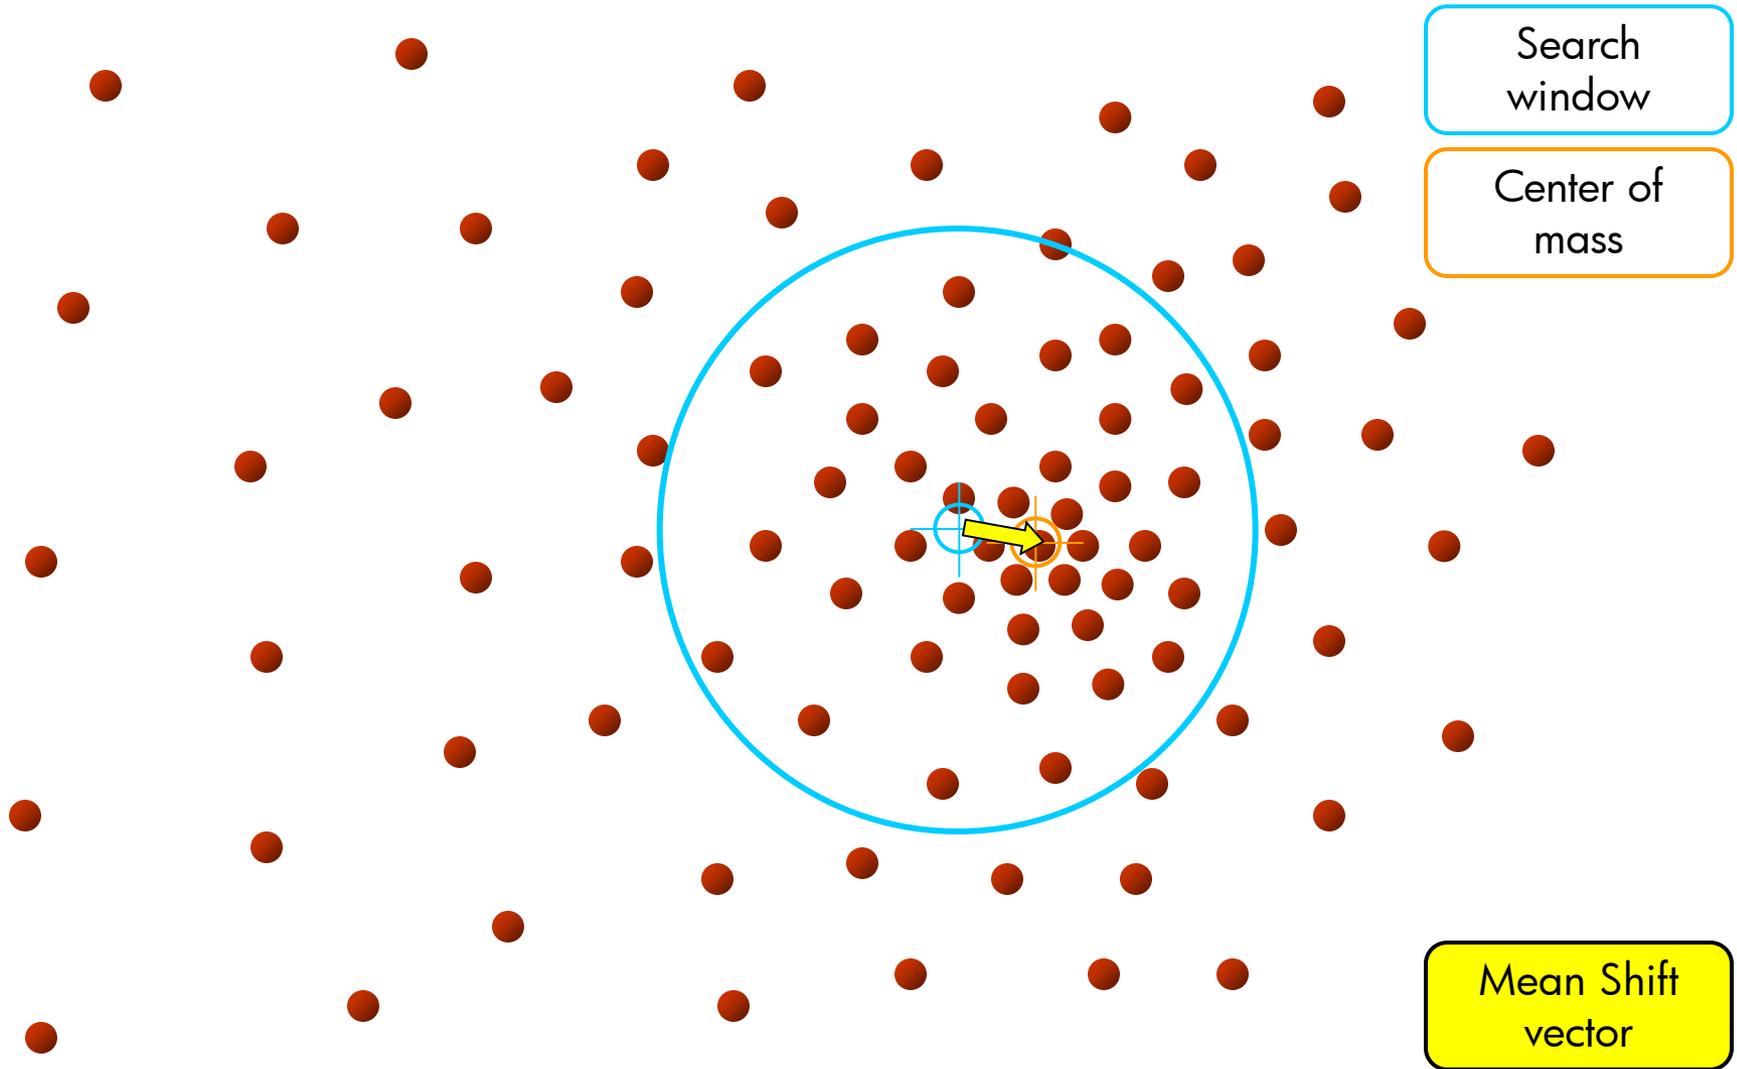
Search window

Center of mass

Mean Shift vector



# Mean shift

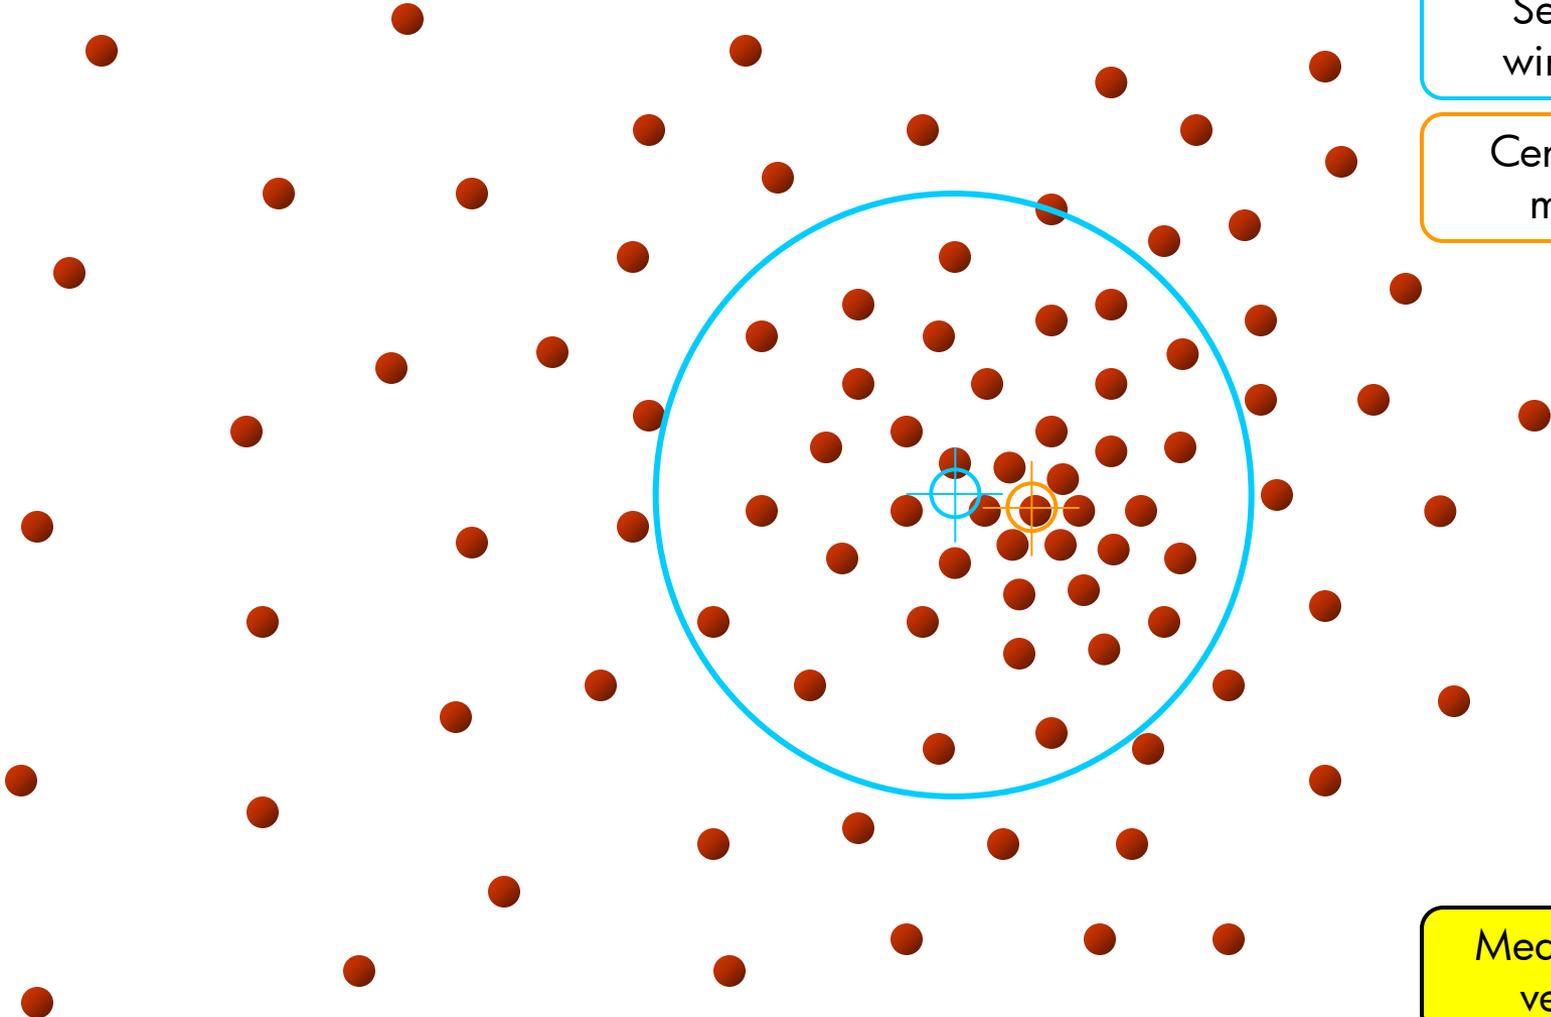


# Mean shift

Search window

Center of mass

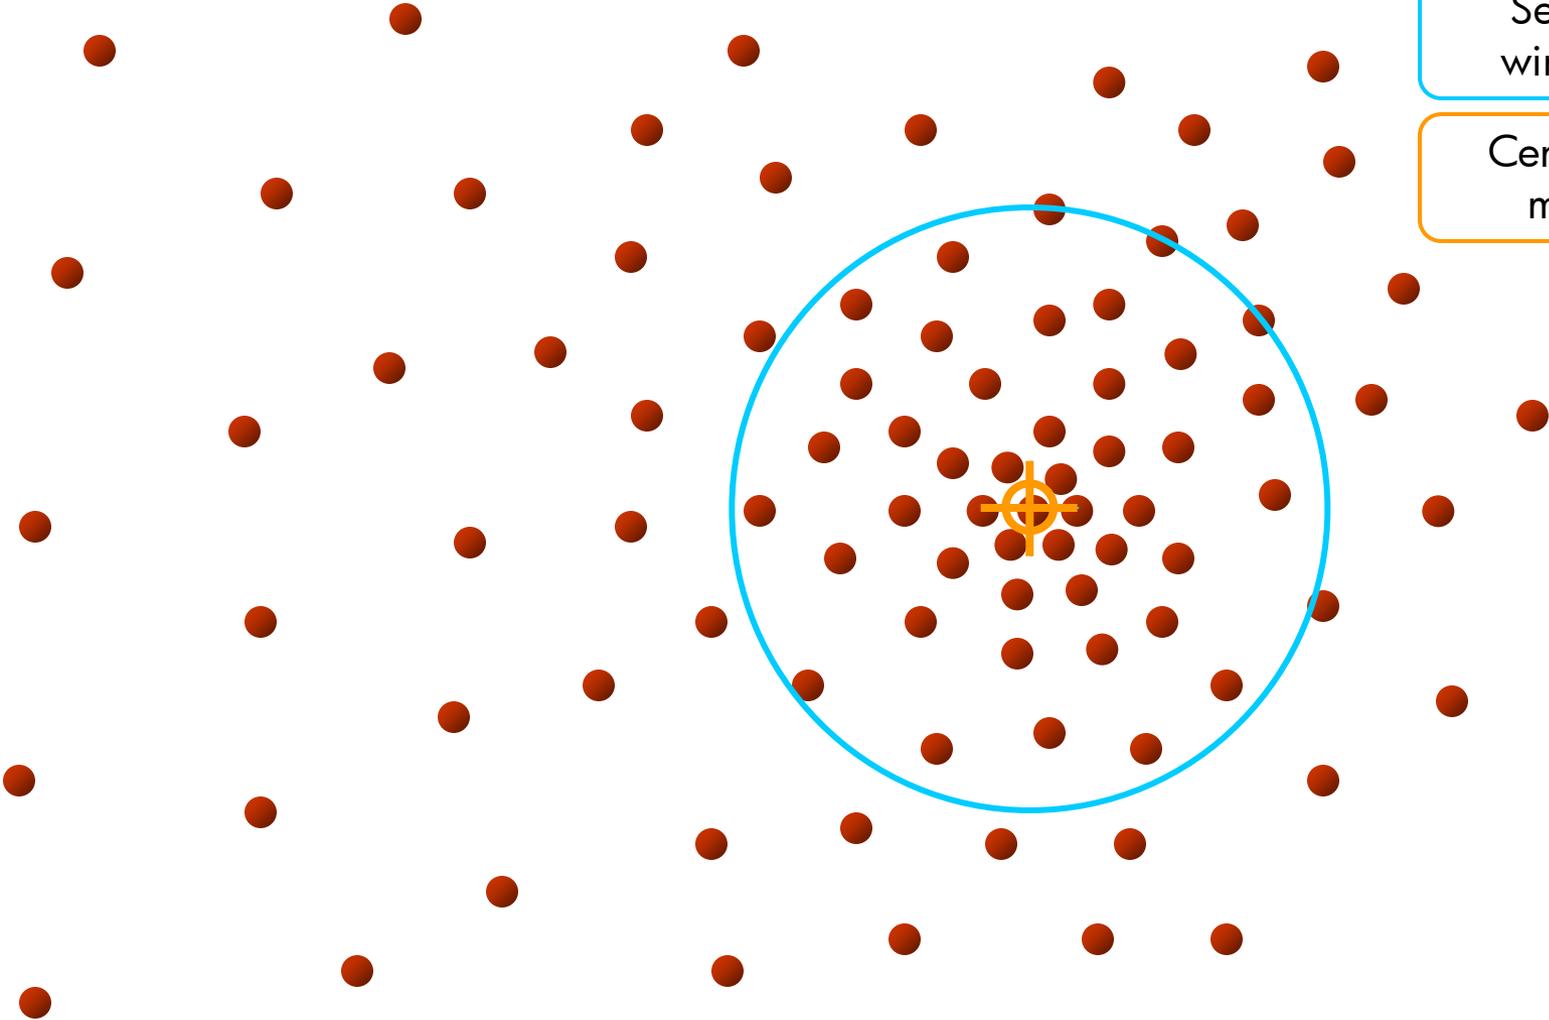
Mean Shift vector



# Mean shift

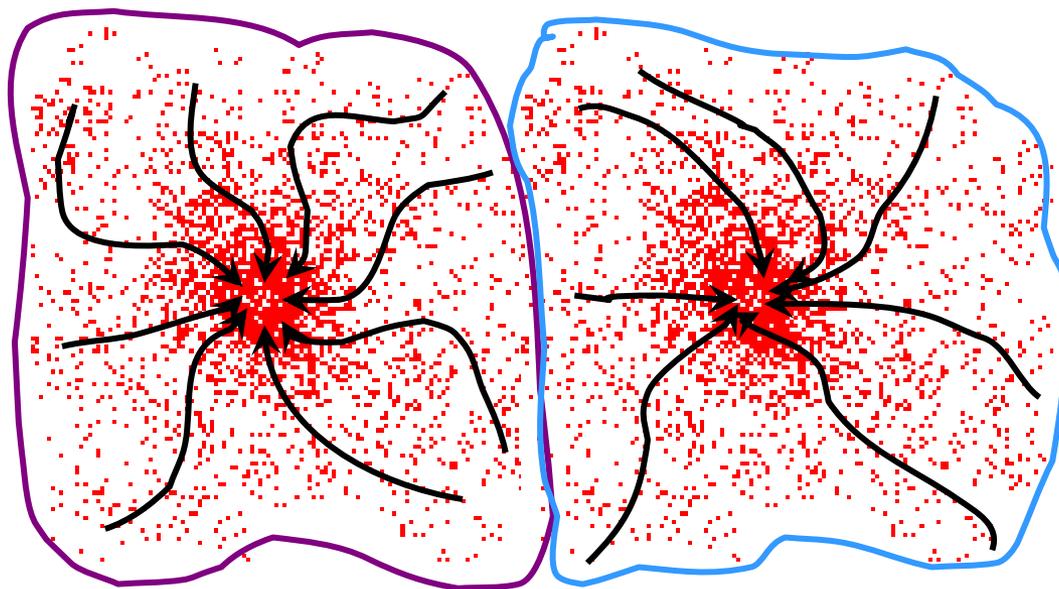
Search window

Center of mass



# Mean shift clustering

- Cluster: all data points in the attraction basin of a mode
- Attraction basin: the region for which all trajectories lead to the same mode



# Mean shift segmentation results



<http://www.caip.rutgers.edu/~comanici/MSPAMI/msPamiResults.html>



# More results



# Mean shift: достоинства и недостатки

- **Достоинства**

- Does not assume spherical clusters
- Just a single parameter (window size)
- Finds variable number of modes
- Robust to outliers

- **Недостатки**

- Output depends on window size
- Computationally expensive
- Does not scale well with dimension of feature space



# Probabilistic clustering

## Basic questions

- what's the probability that a point  $\mathbf{x}$  is in cluster  $m$ ?
- what's the shape of each cluster?

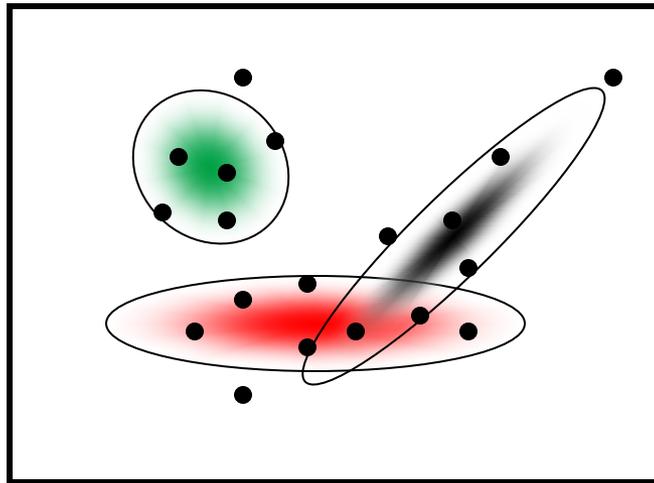
K-means doesn't answer these questions

## Basic idea

- instead of treating the data as a bunch of points, assume that they are all generated by sampling a continuous function
- This function is called a **generative model**
  - defined by a vector of parameters  $\theta$



# Expectation maximization (EM)



## Goal

- find blob parameters  $\theta$  that maximize the likelihood function:

$$P(\text{data}|\theta) = \prod_x P(x|\theta)$$

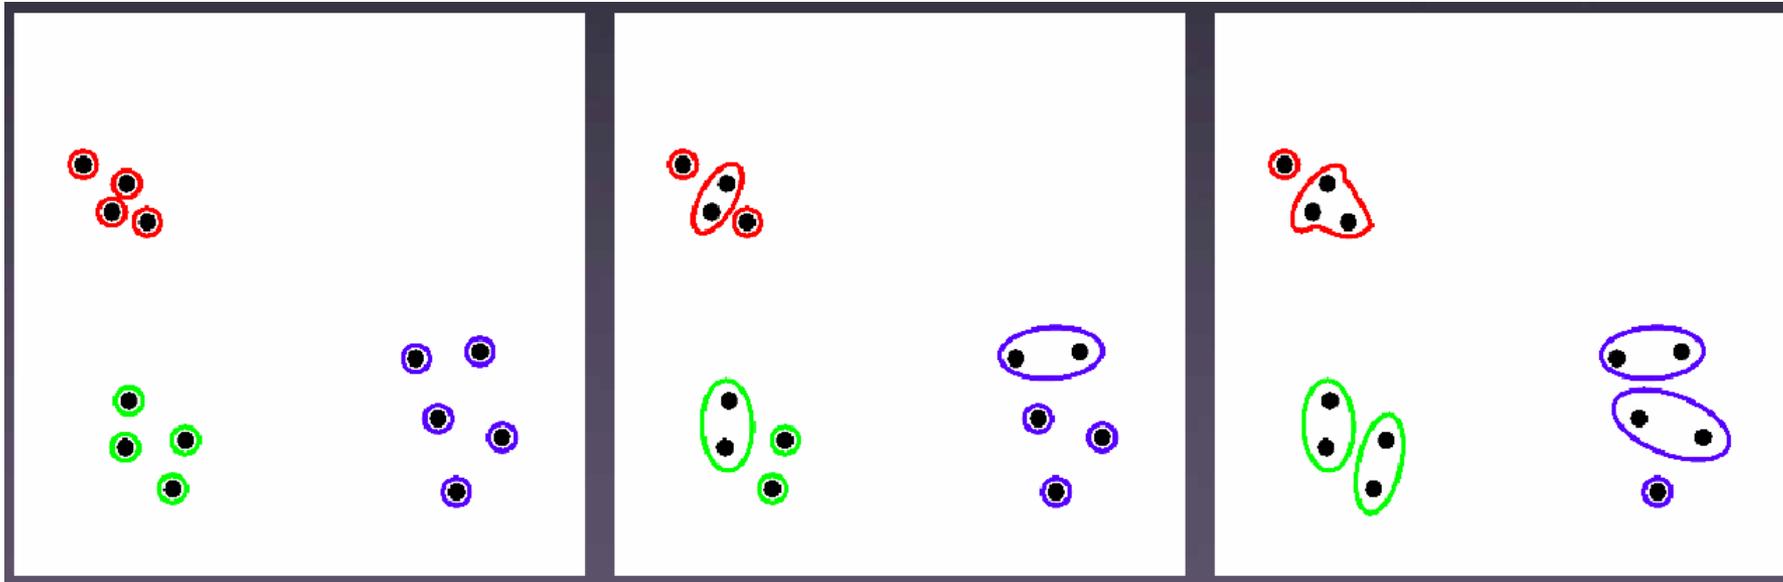
## Approach:

1. E step: given current guess of blobs, compute ownership of each point
2. M step: given ownership probabilities, update blobs to maximize likelihood function
3. repeat until convergence

EM demo: <http://lcn.epfl.ch/tutorial/english/gaussian/html/index.html>



# Иерархическая кластеризация



# Модель для метрического пространства

Когда нет векторов признаков, как таковых, а есть только значение функции расстояния/подобия для каждой пары пикселей:  $d(\cdot, \cdot)$

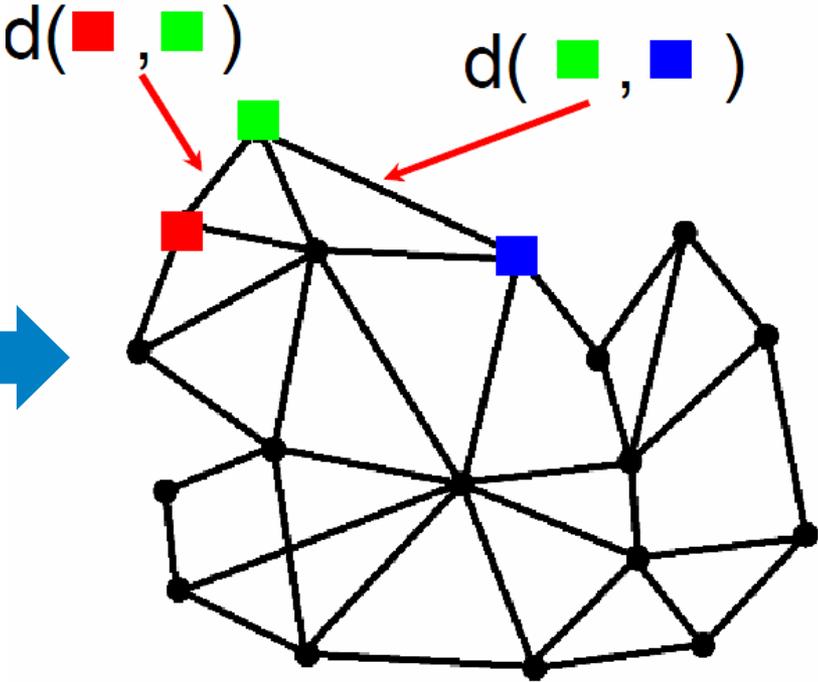


Например:

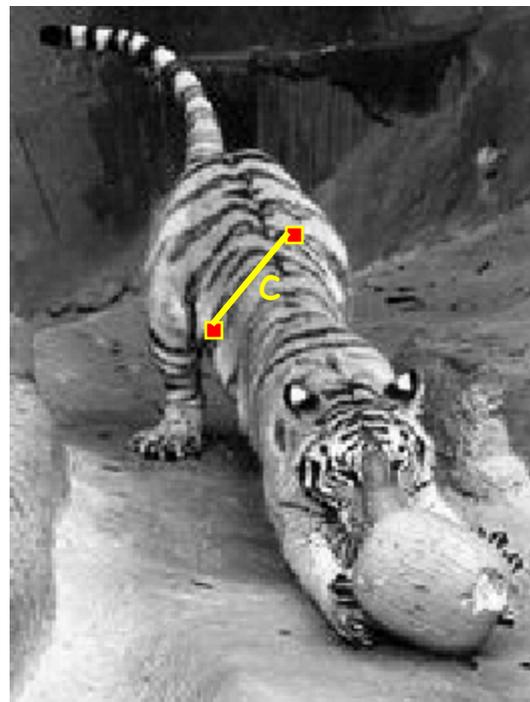
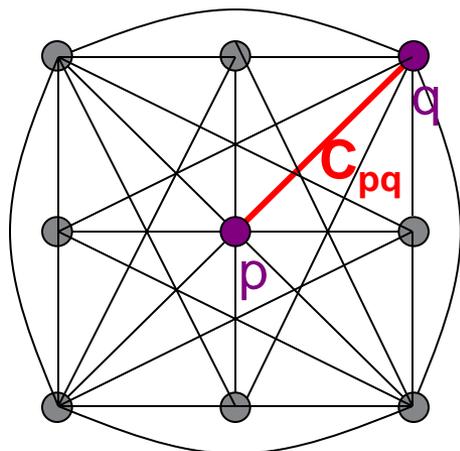
$$d(\text{red}, \text{green}) \gg d(\text{green}, \text{blue})$$

потому что между ■ и ■ нет границы, а между ■ и ■ есть.

# Моделирование при помощи графов



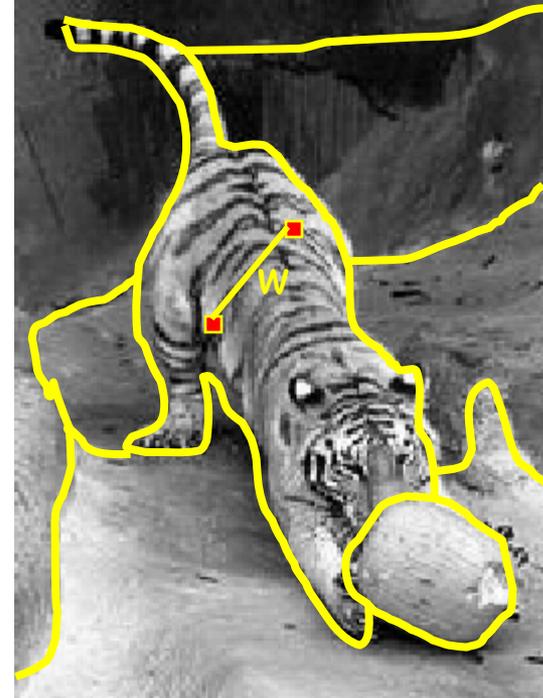
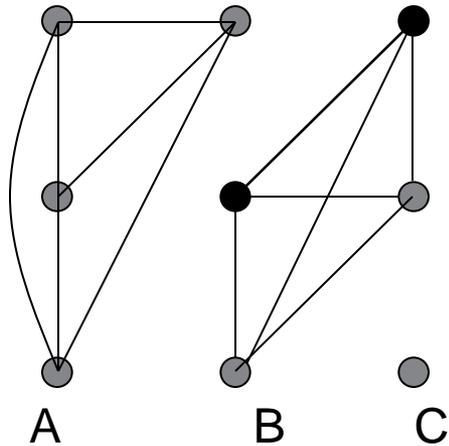
# Automatic graph cut



*Fully-connected graph*

- node for every pixel
- link between every pair of pixels,  $p, q$
- cost  $c_{pq}$  for each link
  - $c_{pq}$  measures *similarity*
    - similarity is *inversely proportional* to difference in color and position

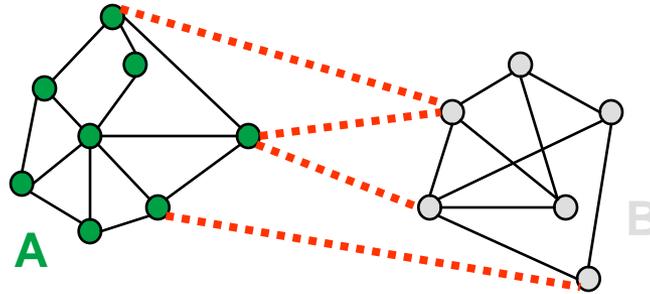
# Segmentation by Graph Cuts



## Break Graph into Segments

- Delete links that cross between segments
- Easiest to break links that have low cost (similarity)
  - similar pixels should be in the same segments
  - dissimilar pixels should be in different segments

# Min cut



## Link Cut

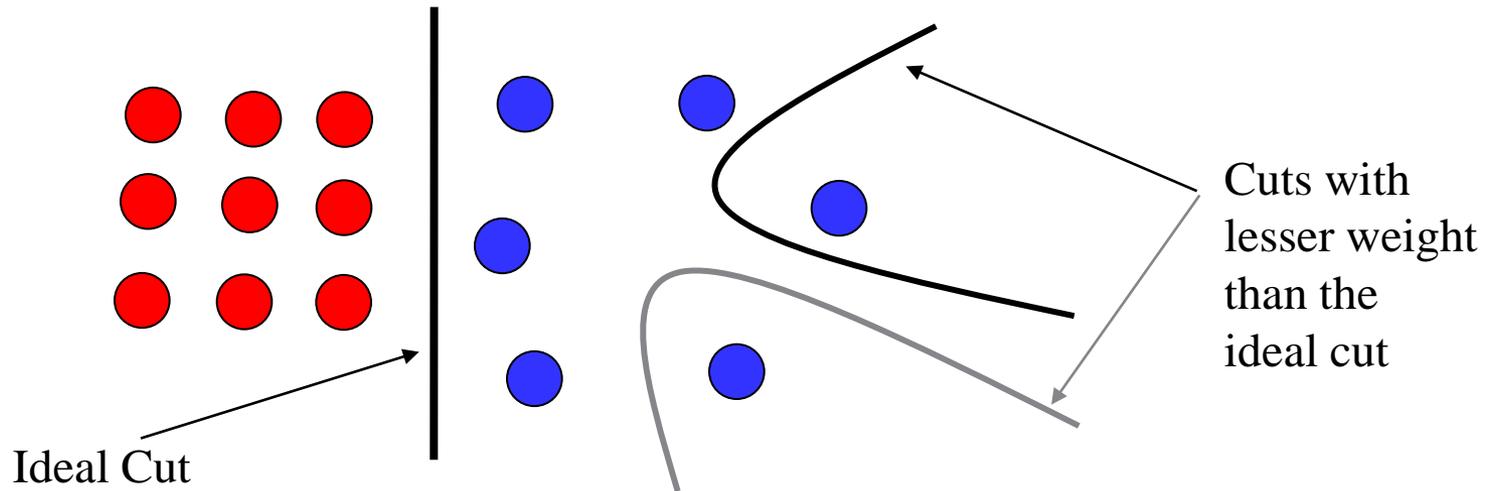
- set of links whose removal makes a graph disconnected
- cost of a cut:

$$cut(A, B) = \sum_{p \in A, q \in B} c_{p,q}$$

Find minimum cut

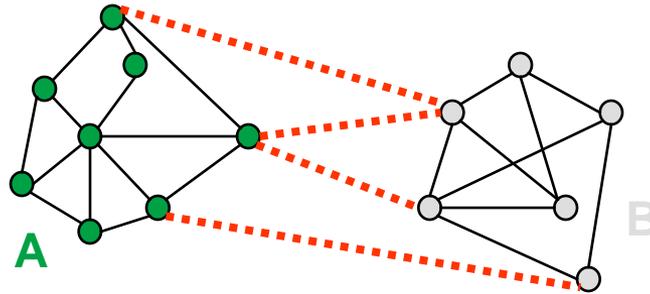
- gives you a segmentation

# But min cut is not always the best cut...



... and it is NP-complete

# Normalized Cut



## Normalized Cut

- a cut penalizes large segments
- fix by normalizing for size of segments

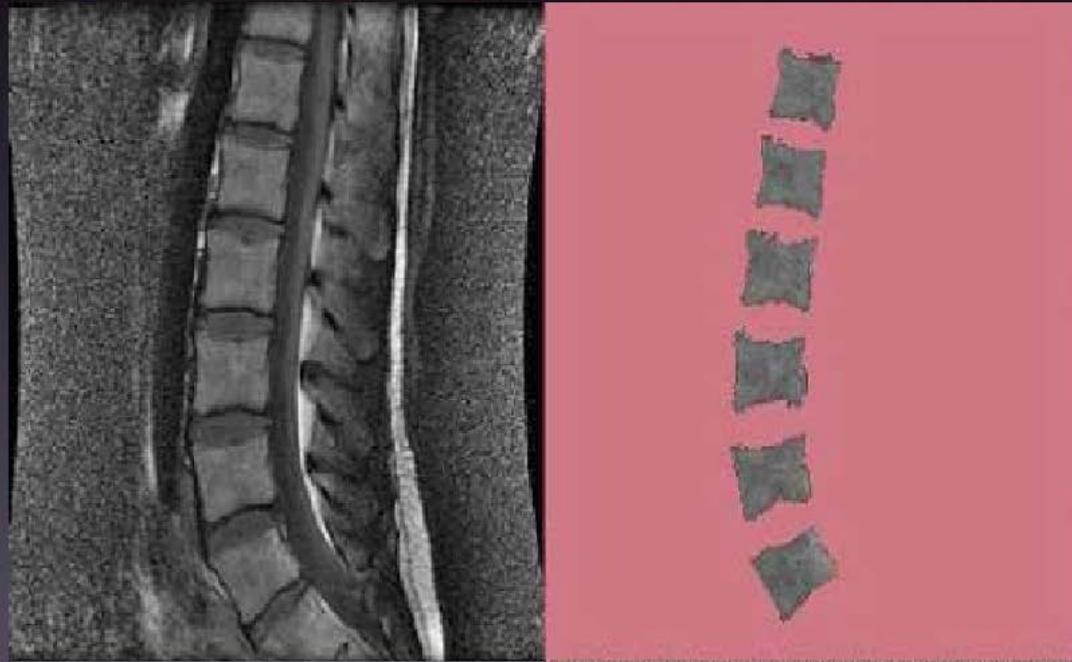
$$Ncut(A, B) = \frac{cut(A, B)}{volume(A)} + \frac{cut(A, B)}{volume(B)}$$

- $volume(A)$  = sum of costs of all edges that touch A

# Примеры сегментации

## Graph-based results

**Normalized  
Cuts**  
Features =  
intensity  
histograms



Normalized Cuts for Spinal MRI Segmentation  
Julio Carballido-Gamio, Serge J. Belongie, and  
Sharmila Majumdar

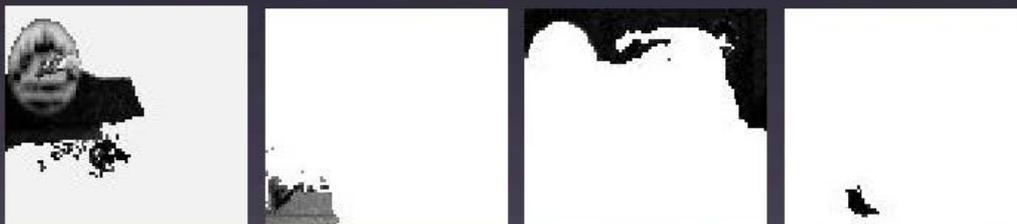


# Примеры сегментации

## Graph-based results

Normalized  
Cuts

Features =  
intensity



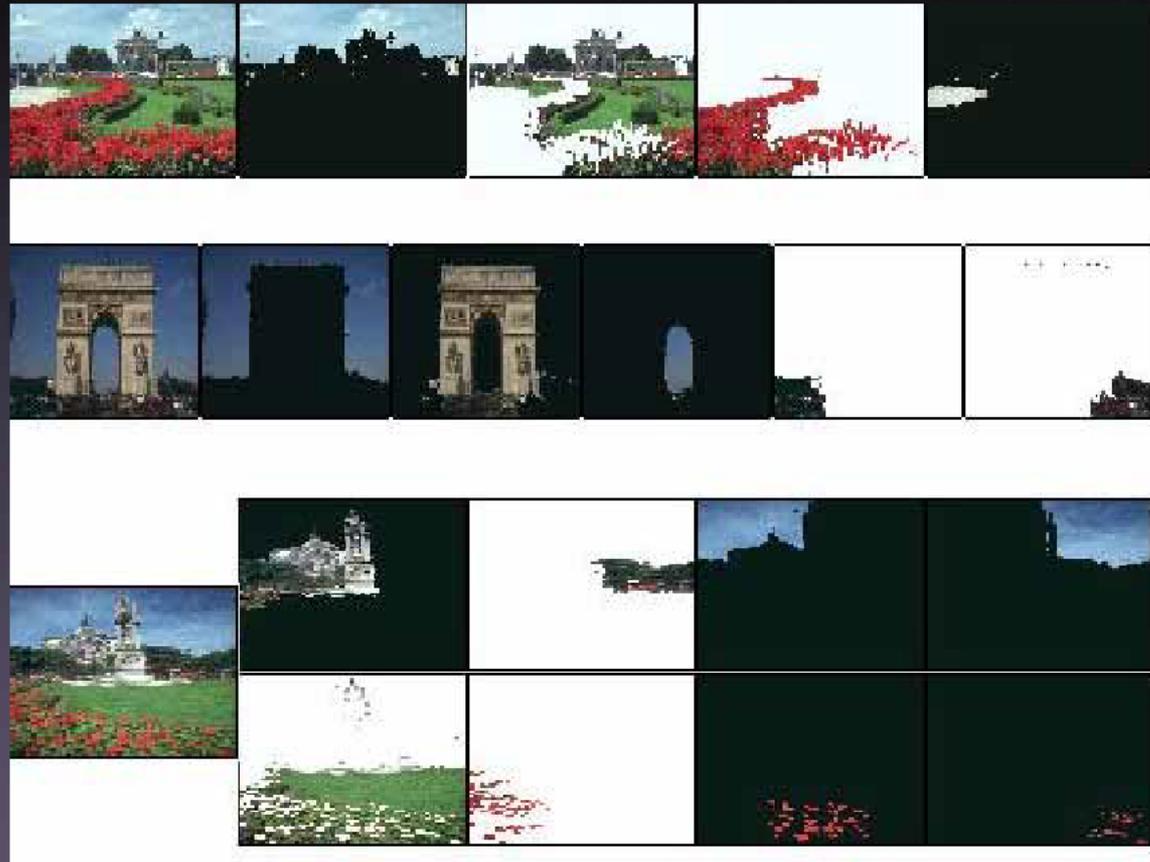
Normalized Cuts and  
Image Segmentation  
Shi and Malik



# Примеры сегментации

## Graph-based results

Normalized  
Cuts  
Features =  
color

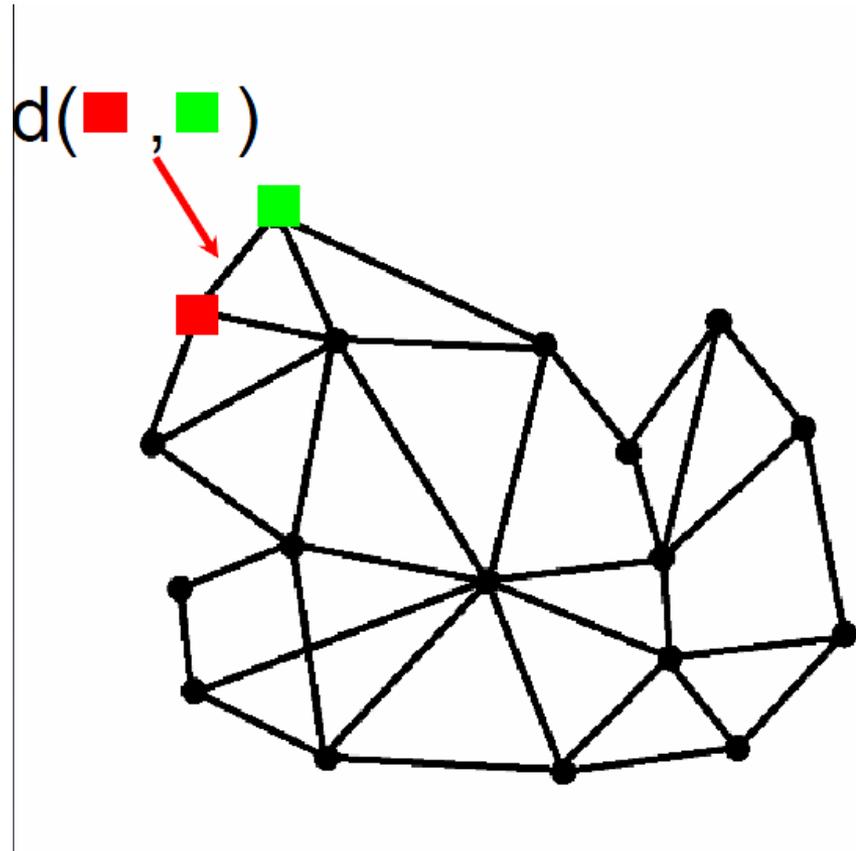
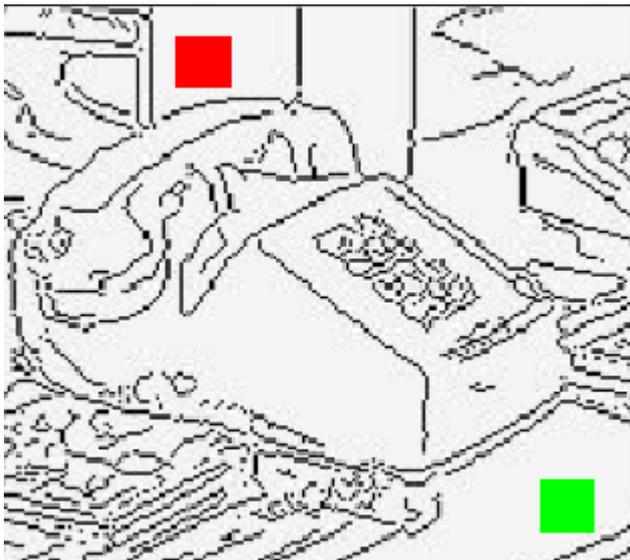


Normalized Cuts and Image  
Segmentation  
Shi and Malik



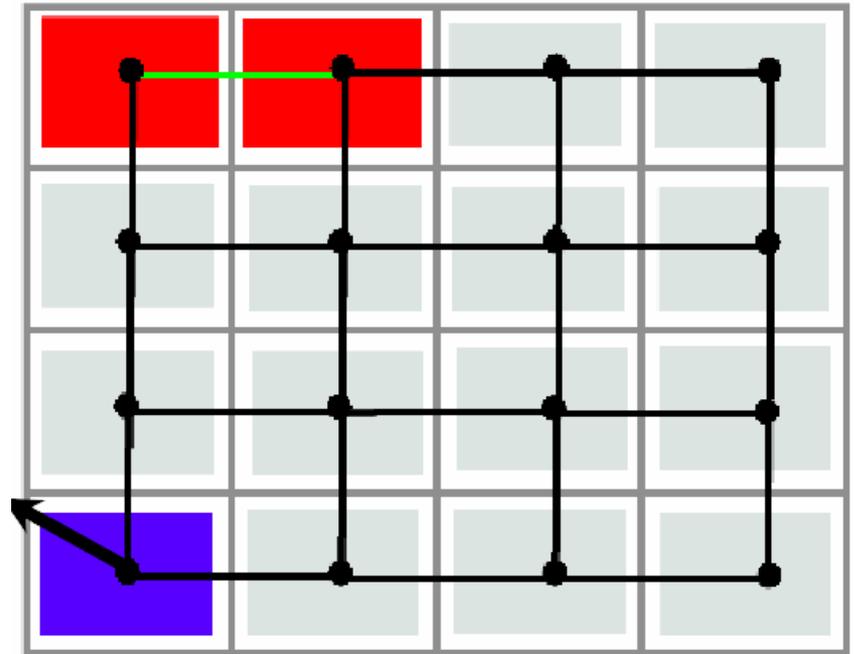
# Использование графов

Полносвязные графы содержат информацию об отношениях для всех возможных пар пикселей



# Использование 2-D решетки

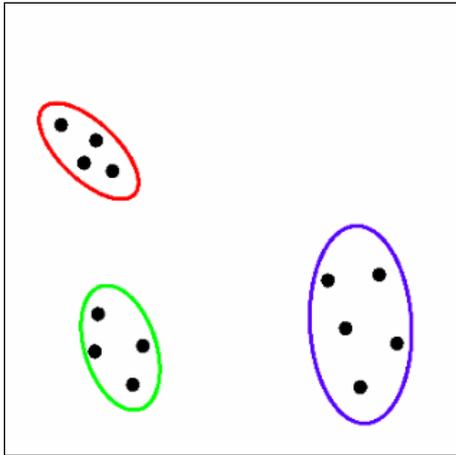
2-D решетка содержит информацию только об отношениях соседних пикселей



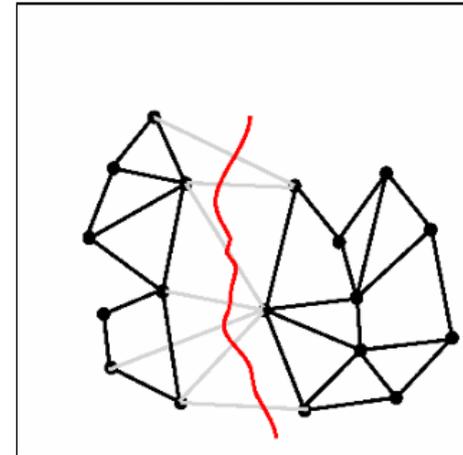
Моделирование при помощи Марковских случайных полей  
(Markov Random Fields, MRF)

# Математические модели

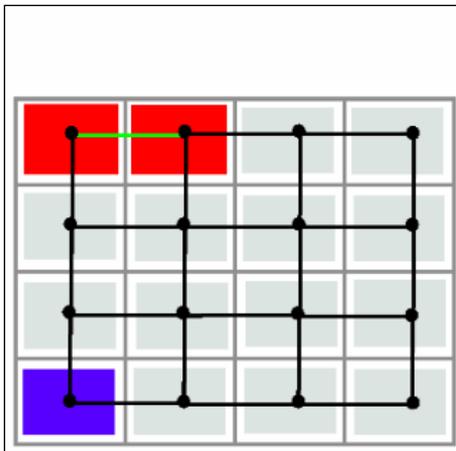
Кластеры в пространстве признаков



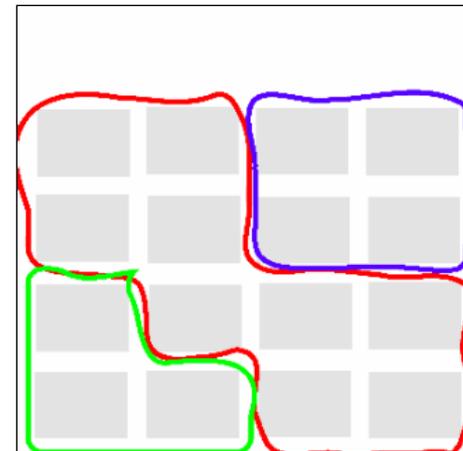
Полносвязный граф



2-D решетка



Множество регионов

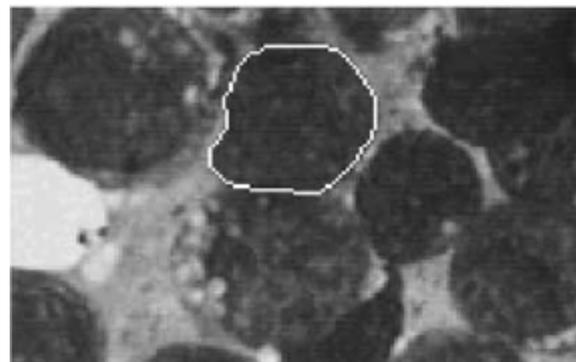
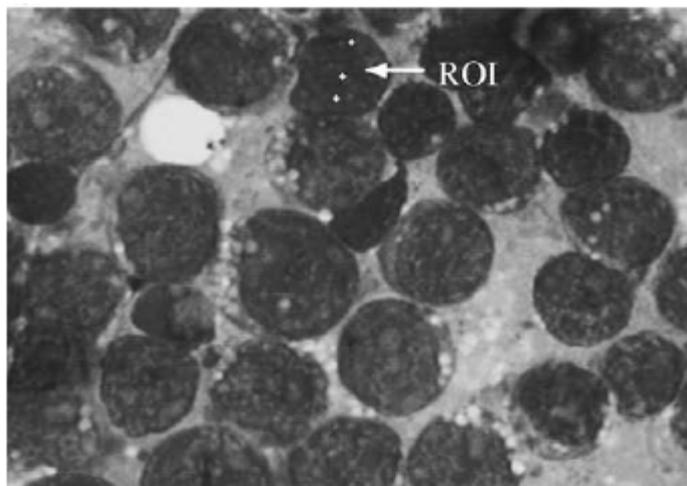


# Методы сегментации «сверху-вниз»

Деформируемые контуры

Deformable contours/active contours/snakes

- Если известно, сколько сегментов хотим выделить на изображении
- Если есть возможность получить начальное предсказание, где проходит контур
- Если сегменты имеют относительно простую форму
- Если есть возможность получить вводную информацию о пользователе

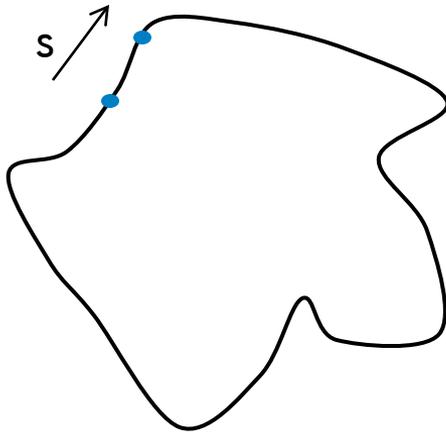


Lei He, Zhigang Peng, Bryan Everding, Xun Wang, Chia Y. Han, Kenneth L. Weiss, William G. Wee,  
A comparative study of deformable contour methods on medical image segmentation,  
Image and Vision Computing 26 (2008) 141–163

# Деформируемые контуры

Подзадачи: параметризация

- Как математически описать контур?  
Сколько параметров потребуется задать?



Каждая точка контура  
имеет координаты  $(x_i(s), y_i(s))$

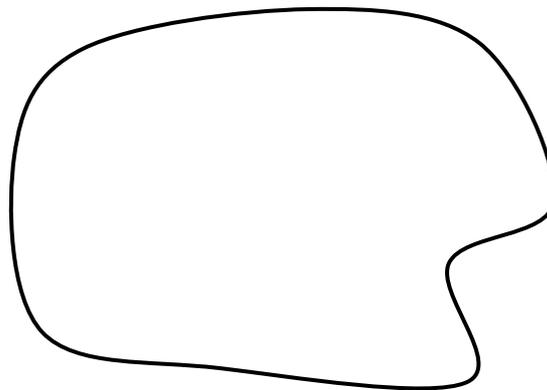
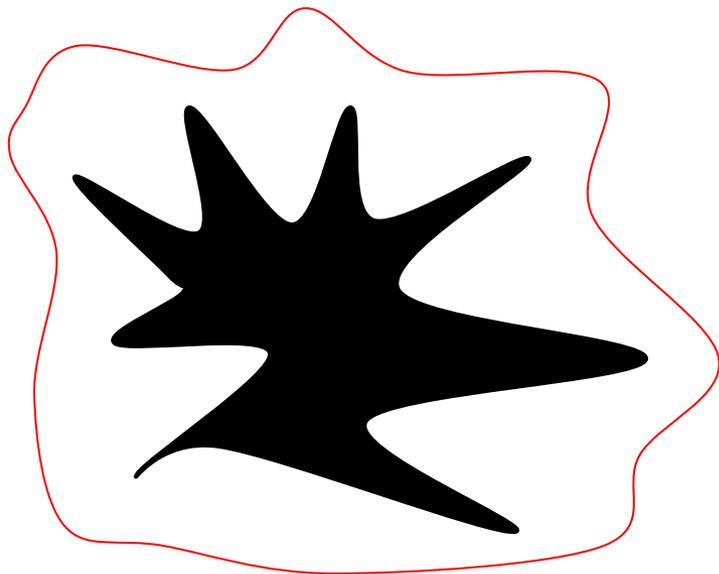
# Деформируемые контуры

Подзадачи: задать энергию контура

- Как математически задать, каким нам хочется видеть контур?

Например:

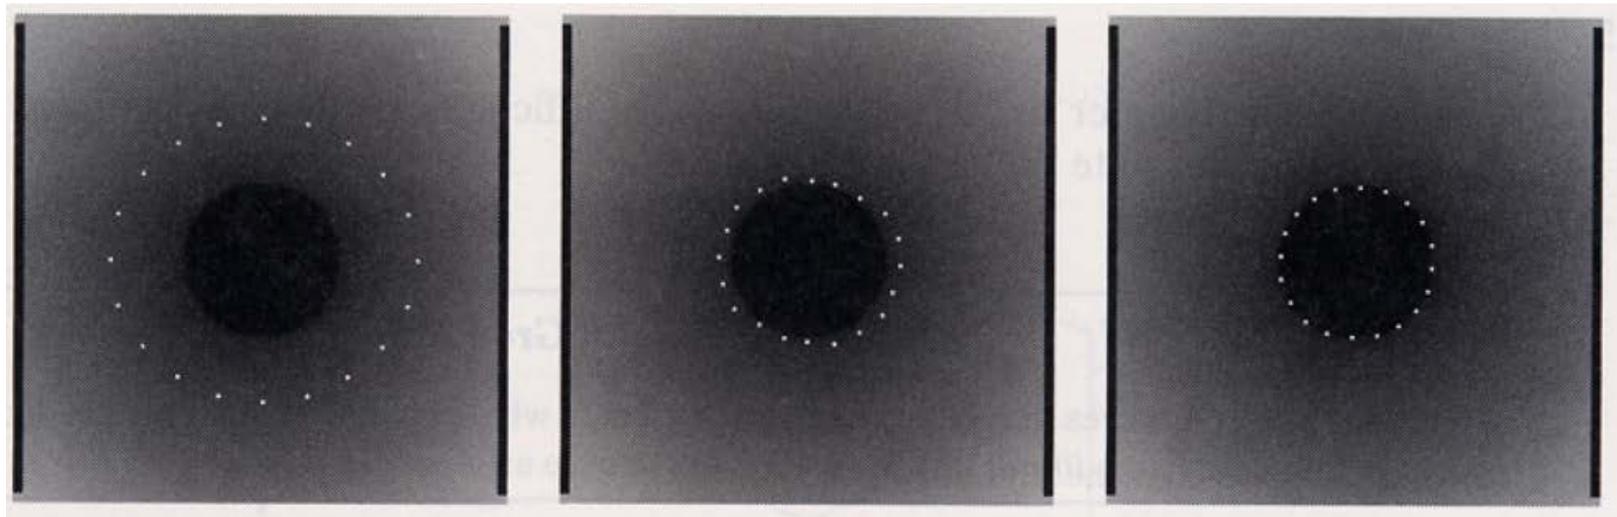
- Чтобы вдоль контур находился в точках сильного перепада яркости
- Чтобы контур был не сложным



# Деформируемые контуры

Подзадачи: оптимизация

- Подобрать параметры для контура так, чтобы минимизировать энергию контура



# Параметризация

- Кусочно-линейные функции
- Сплаины
- Описание спектра (Фурье, вейвлеты)



# Задание энергии контура

$$E = \int_c \alpha(s)E_{internal} + \beta(s)E_{image} + \gamma(s)E_{user} ds$$

$E_{internal}$  – внутренняя энергия контура, задает желаемые свойства контура вне зависимости от свойств внутренней области

Например:

- Непрерывность контура – минимизация первой производной
- Гладкость контура – минимизация второй производной



# Задание энергии контура

$$E = \int_c \alpha(s)E_{internal} + \beta(s)E_{image} + \gamma(s)E_{user} ds$$

$E_{image}$  – задает желаемые свойства внутренней/внешней области

Например:

- Перепад яркости – максимизация градиента яркости



# Задание энергии контура

$$E = \int_c \alpha(s)E_{internal} + \beta(s)E_{image} + \gamma(s)E_{user} ds$$

$E_{user}$  – задает дополнительные внешние условия

Например:

- Набор контрольных точек и минимизация/максимизация расстояния до них



# Оптимизация

## Градиентный спуск

1. Ищем минимум энергии – точку, где ее производная равна нулю
2. Перемещаем контур по направлению уменьшения градиента энергии
3. Повторяем шаг 2 до тех пор, пока не окажемся в точке минимума



# Berkeley Segmentation DataSet [BSDS]



D. Martin, C. Fowlkes, D. Tal, J. Malik. "A Database of Human Segmented Natural Images and its Application to Evaluating Segmentation Algorithms and Measuring Ecological Statistics", [ICCV](#), 2001



# Заключение

- Bottom-up
  - Определение критериев «общности»
  - Построение математической модели
  - Найти решение в выбранной модели
- Top-down (active contours)
  - Параметризация
  - Построение функции энергии контура
  - Оптимизация

