

# Кластеризация и частичное обучение

К. В. Воронцов

vokov@forecsys.ru

Этот курс доступен на странице вики-ресурса

<http://www.MachineLearning.ru/wiki>

«Машинное обучение (курс лекций, К.В.Воронцов)»

МФТИ • 5 декабря 2020

## 1 Задачи кластеризации и частичного обучения

- Задача кластеризации
- Задача частичного обучения
- Критерии качества кластеризации

## 2 Алгоритмы кластеризации

- Метод  $K$ -средних
- Алгоритм DBSCAN
- Иерархические методы

## 3 Частичное обучение на основе классификации

- Обёртки над методами классификации
- Трансдуктивный SVM
- Регуляризация правдоподобия

## Постановка задачи кластеризации

**Дано:**

$X$  — пространство объектов;

$X^\ell = \{x_1, \dots, x_\ell\}$  — обучающая выборка;

$\rho: X \times X \rightarrow [0, \infty)$  — функция расстояния между объектами.

**Найти:**

$Y$  — множество кластеров,

$a: X \rightarrow Y$  — алгоритм кластеризации,

такие, что:

— каждый кластер состоит из близких объектов;

— объекты разных кластеров существенно различны.

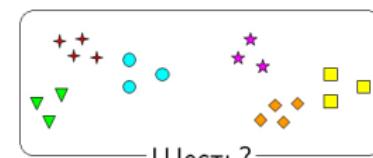
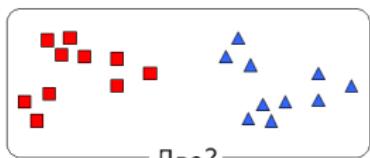
Это задача обучения без учителя (*unsupervised learning*).

# Некорректность задачи кластеризации

Решение задачи кластеризации принципиально неоднозначно:

- точной постановки задачи кластеризации нет;
- существует много критериев качества кластеризации;
- существует много эвристических методов кластеризации;
- число кластеров  $|Y|$ , как правило, неизвестно заранее;
- результат кластеризации сильно зависит от метрики  $\rho$ , выбор которой также является эвристикой.

**Пример:** сколько здесь кластеров?



## Цели кластеризации

- Упростить дальнейшую обработку данных, разбить множество  $X^\ell$  на группы схожих объектов чтобы работать с каждой группой в отдельности (задачи классификации, регрессии, прогнозирования).
- Сократить объём хранимых данных, оставив по одному представителю от каждого кластера (задачи сжатия данных).
- Выделить нетипичные объекты, которые не подходят ни к одному из кластеров (задачи одноклассовой классификации).
- Построить иерархию множества объектов, пример — классификация животных и растений К.Линнея (задачи таксономии).

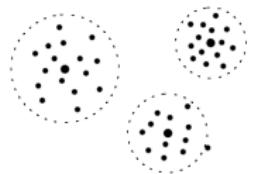
## Типы кластерных структур



внутрикластерные расстояния, как правило,  
меньше межкластерных



ленточные кластеры



кластеры с центром

## Типы кластерных структур



кластеры могут соединяться перемычками



кластеры могут накладываться на разреженный фон из редко расположенных объектов



кластеры могут перекрываться

## Типы кластерных структур



кластеры могут образовываться не по сходству, а по иным типам регулярностей

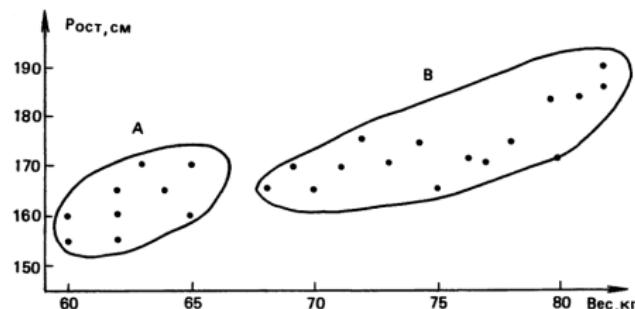


кластеры могут вообще отсутствовать

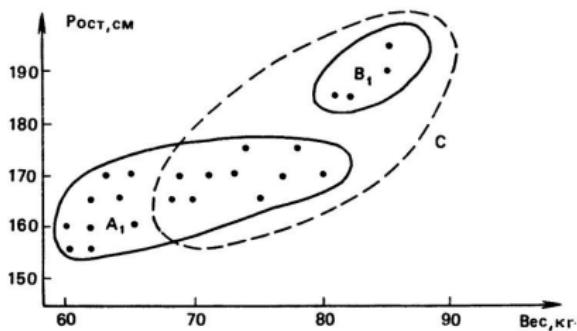
- Каждый метод кластеризации имеет свои ограничения и выделяет кластеры лишь некоторых типов.
- Понятие «тип кластерной структуры» зависит от метода и также не имеет формального определения.

# Проблема чувствительности к выбору метрики

Результат зависит от нормировки признаков:



А — студентки,  
Б — студенты



после перенормировки  
(сжали ось «вес» вдвое)

## Постановка задачи частичного обучения (SSL)

**Дано:**

множество объектов  $X$ , множество классов  $Y$ ;

$X^k = \{x_1, \dots, x_k\}$  — размеченные объекты (labeled data);  
 $\{y_1, \dots, y_k\}$

$U = \{x_{k+1}, \dots, x_\ell\}$  — неразмеченные объекты (unlabeled data).

**Два варианта постановки задачи:**

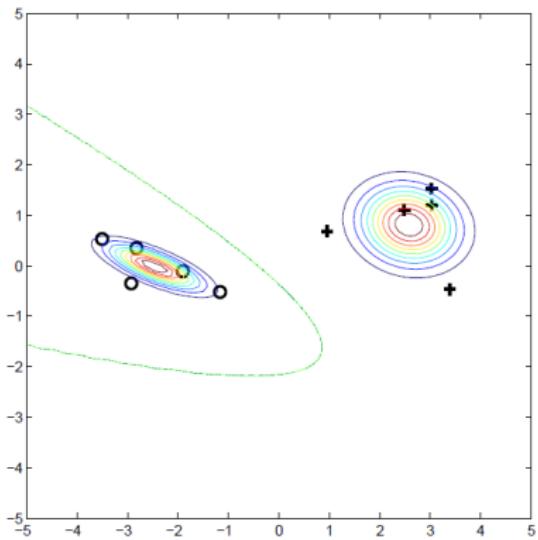
- *Частичное обучение* (semi-supervised learning):  
построить алгоритм классификации  $a: X \rightarrow Y$ .
- *Трансдуктивное обучение* (transductive learning):  
зная **все**  $\{x_{k+1}, \dots, x_\ell\}$ , получить метки  $\{a_{k+1}, \dots, a_\ell\}$ .

**Типичные приложения:**

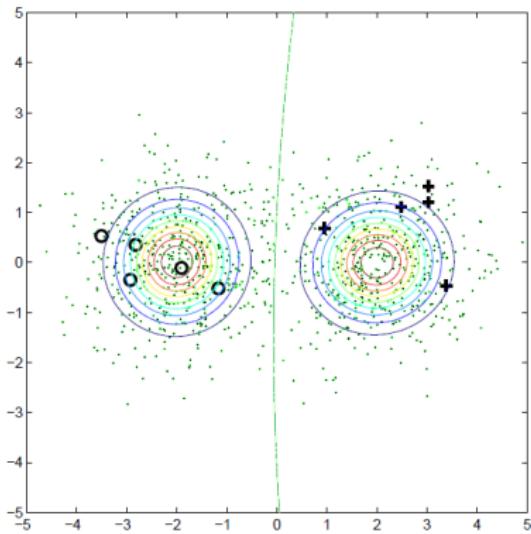
классификация и каталогизация текстов, изображений, и т. п.

# SSL не сводится к классификации

**Пример 1.** плотности классов, восстановленные:  
по размеченным данным  $X^k$

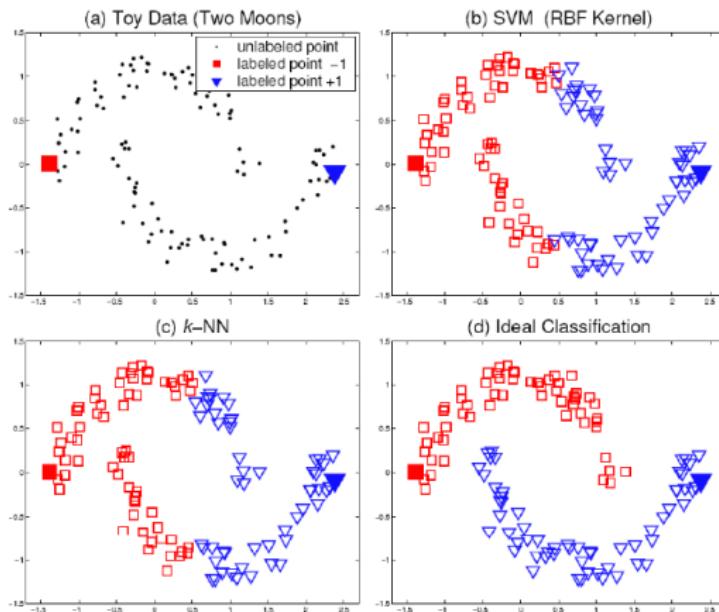


по полным данным  $X^\ell$



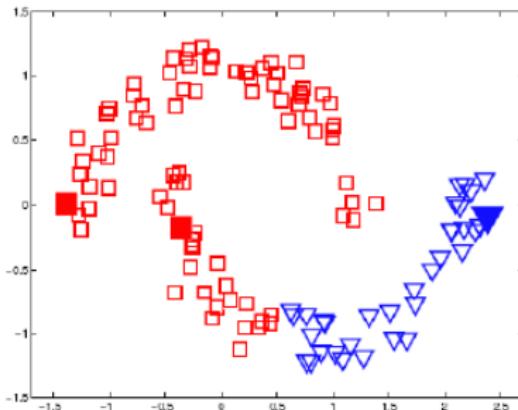
# SSL не сводится к классификации

**Пример 2.** Методы классификации не учитывают кластерную структуру неразмеченных данных



## Однако и к кластеризации SSL также не сводится

**Пример 3.** Методы кластеризации не учитывают приоритетность разметки над кластерной структурой.



## Качество кластеризации в метрическом пространстве

Пусть известны только попарные расстояния между объектами.

- Среднее внутрикластерное расстояние:

$$F_0 = \frac{\sum_{i < j} [a_i = a_j] \rho(x_i, x_j)}{\sum_{i < j} [a_i = a_j]} \rightarrow \min.$$

- Среднее межкластерное расстояние:

$$F_1 = \frac{\sum_{i < j} [a_i \neq a_j] \rho(x_i, x_j)}{\sum_{i < j} [a_i \neq a_j]} \rightarrow \max.$$

- Отношение пары функционалов:  $F_0/F_1 \rightarrow \min.$

## Качество кластеризации в линейном векторном пространстве

Пусть объекты  $x_i$  задаются векторами  $(f_1(x_i), \dots, f_n(x_i))$ .

- Сумма средних внутрикластерных расстояний:

$$\Phi_0 = \sum_{a \in Y} \frac{1}{|X_a|} \sum_{i: a_i=a} \rho(x_i, \mu_a) \rightarrow \min,$$

$X_a = \{x_i \in X^\ell \mid a_i = a\}$  — кластер  $a$ ,

$\mu_a$  — центр масс кластера  $a$ .

- Сумма межкластерных расстояний:

$$\Phi_1 = \sum_{a,b \in Y} \rho(\mu_a, \mu_b) \rightarrow \max.$$

- Отношение пары функционалов:  $\Phi_0/\Phi_1 \rightarrow \min$ .

## Метод K-средних (*K-means*) для кластеризации

Минимизация суммы квадратов внутрикластерных расстояний:

$$\sum_{i=1}^{\ell} \|x_i - \mu_{a_i}\|^2 \rightarrow \min_{\{a_i\}, \{\mu_a\}}, \quad \|x_i - \mu_a\|^2 = \sum_{j=1}^n (f_j(x_i) - \mu_{aj})^2$$

### Алгоритм Ллойда

**вход:**  $X^\ell$ ,  $K = |Y|$ ; **выход:** центры кластеров  $\mu_a$ ,  $a \in Y$ ;

$\mu_a :=$  начальное приближение центров, для всех  $a \in Y$ ;

#### повторять

отнести каждый  $x_i$  к ближайшему центру:

$$a_i := \arg \min_{a \in Y} \|x_i - \mu_a\|, \quad i = 1, \dots, \ell;$$

вычислить новые положения центров:

$$\mu_a := \frac{\sum_{i=1}^{\ell} [a_i = a] x_i}{\sum_{i=1}^{\ell} [a_i = a]}, \quad a \in Y;$$

**пока**  $a_i$  не перестанут изменяться;

## Метод K-средних (*K-means*) для частичного обучения

### Модификация алгоритма Ллойда при наличии размеченных объектов $\{x_1, \dots, x_k\}$

**вход:**  $X^\ell$ ,  $K = |Y|$ ;

**выход:** центры кластеров  $\mu_a$ ,  $a \in Y$ ;

$\mu_a :=$  начальное приближение центров, для всех  $a \in Y$ ;

**повторять**

отнести каждый  $x_i \in U$  к ближайшему центру:

$$a_i := \arg \min_{a \in Y} \|x_i - \mu_a\|, \quad i = k+1, \dots, \ell;$$

вычислить новые положения центров:

$$\mu_a := \frac{\sum_{i=1}^{\ell} [a_i = a] x_i}{\sum_{i=1}^{\ell} [a_i = a]}, \quad a \in Y;$$

**пока**  $a_i$  не перестанут изменяться;

## Метод K-средних — упрощение EM-алгоритма для GMM

**EM-алгоритм:** максимизация правдоподобия для разделения смеси гауссиан (GMM, Gaussian Mixture Model)

начальное приближение  $w_a, \mu_a, \Sigma_a$  для всех  $a \in Y$ ;  
**повторять**

Е-шаг: отнести каждый  $x_i$  к ближайшим центрам:

$$g_{ia} := P(a|x_i) \equiv \frac{w_a p_a(x_i)}{\sum_y w_y p_y(x_i)}, \quad a \in Y, \quad i = 1, \dots, \ell;$$

$$a_i := \arg \max_{a \in Y} g_{ia}, \quad i = 1, \dots, \ell;$$

М-шаг: вычислить новые положения центров:

$$\mu_{ad} := \frac{1}{\ell w_a} \sum_{i=1}^{\ell} g_{ia} f_d(x_i), \quad a \in Y, \quad d = 1, \dots, n;$$

$$\sigma_{ad}^2 := \frac{1}{\ell w_a} \sum_{i=1}^{\ell} g_{ia} (f_d(x_i) - \mu_{ad})^2, \quad a \in Y, \quad d = 1, \dots, n;$$

$$w_a := \frac{1}{\ell} \sum_{i=1}^{\ell} g_{ia}, \quad a \in Y;$$

**пока**  $a_i$  не перестанут изменяться;

## Сравнение EM-алгоритма для GMM и метода k-средних

### Основные отличия GMM-EM и k-means:

- GMM-EM: мягкая кластеризация:  $g_{ia} = P(a|x_i)$   
k-means: жёсткая кластеризация:  $g_{ia} = [a_i = a]$
- GMM-EM: кластеры эллиптические, настраиваемые  
k-means: кластеры сферические, не настраиваемые

### Гибриды (упрощение GMM-EM — усложнение k-means):

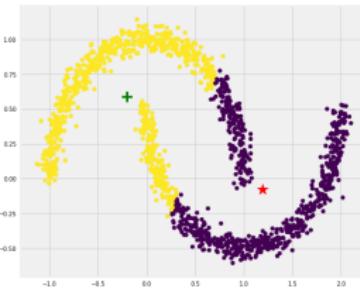
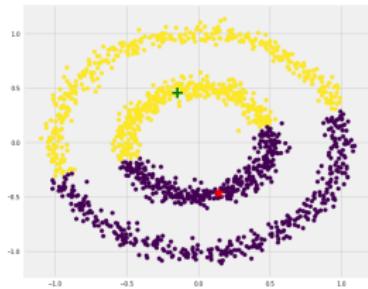
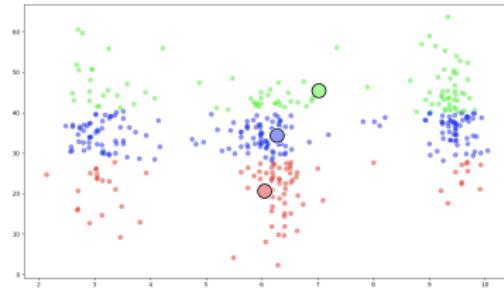
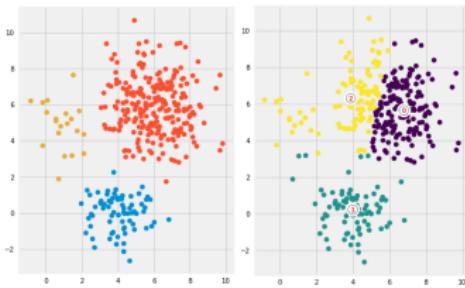
- GMM-EM с жёсткой кластеризацией на E-шаге
- GMM-EM без настройки дисперсий (сферические гауссианы)

### Недостатки k-means:

- чувствительность к выбору начального приближения
- медленная сходимость (пользуйтесь k-means++)

## Примеры неудачной кластеризации $k$ -means

Причина — неудачное начальное приближение или существенная негауссовость кластеров



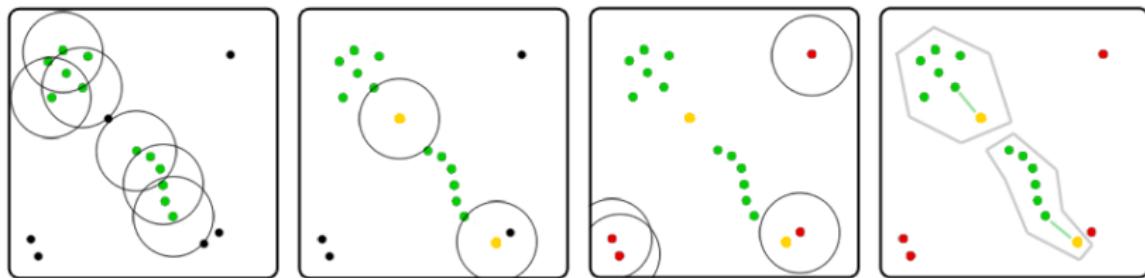
# Алгоритм кластеризации DBSCAN

(Density-Based Spatial Clustering of Applications with Noise)

Объект  $x \in U$ , его  $\varepsilon$ -окрестность  $U_\varepsilon(x) = \{u \in U : \rho(x, u) \leq \varepsilon\}$

Каждый объект может быть одного из трёх типов:

- корневой: имеющий плотную окрестность,  $|U_\varepsilon(x)| \geq m$
- граничный: не корневой, но в окрестности корневого
- шумовой (выброс): не корневой и не граничный



*Ester, Kriegel, Sander, Xu. A density-based algorithm for discovering clusters in large spatial databases with noise. KDD-1996.*

## Алгоритм кластеризации DBSCAN

**вход:** выборка  $X^\ell = \{x_1, \dots, x_\ell\}$ ; параметры  $\varepsilon$  и  $m$ ;

**выход:** разбиение выборки на кластеры и шумовые выбросы;

$U := X^\ell$  — непомеченные;  $a := 0$ ;

**пока** в выборке есть непомеченные точки,  $U \neq \emptyset$ :

    взять случайную точку  $x \in U$ ;

**если**  $|U_\varepsilon(x)| < m$  **то**

        пометить  $x$  как, возможно, шумовой;

**иначе**

        создать новый кластер:  $K := U_\varepsilon(x)$ ;  $a := a + 1$ ;

**для всех**  $x' \in K$ , не помеченных или шумовых

**если**  $|U_\varepsilon(x')| \geq m$  **то**  $K := K \cup U_\varepsilon(x')$ ;

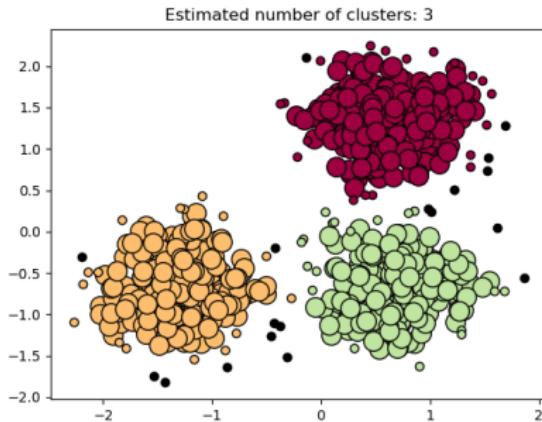
**иначе** пометить  $x'$  как граничный кластера  $K$ ;

$a_i := a$  для всех  $x_i \in K$ ;

$U := U \setminus K$ ;

## Преимущества алгоритма DBSCAN

- быстрая кластеризация больших данных:  
 $O(\ell^2)$  в худшем случае,  
 $O(\ell \ln \ell)$  при эффективной реализации  $U_\varepsilon(x)$ ;
- кластеры произвольной формы (долой центры!);
- деление объектов на корневые, граничные, шумовые.



## Агломеративная иерархическая кластеризация

Алгоритм иерархической кластеризации (Ланс, Уильямс, 1967):  
итеративный пересчёт расстояний  $R_{UV}$  между кластерами  $U, V$ .

$C_1 := \{\{x_1\}, \dots, \{x_\ell\}\}$  — все кластеры 1-элементные;

$R_{\{x_i\}\{x_j\}} := \rho(x_i, x_j)$  — расстояния между ними;

**для всех**  $t = 2, \dots, \ell$  ( $t$  — номер итерации):

найти в  $C_{t-1}$  пару кластеров  $(U, V)$  с минимальным  $R_{UV}$ ;

слить их в один кластер:

$W := U \cup V$ ;

$C_t := C_{t-1} \cup \{W\} \setminus \{U, V\}$ ;

**для всех**  $S \in C_t$

вычислить  $R_{WS}$  по формуле Ланса-Уильямса:

$R_{WS} := \alpha_U R_{US} + \alpha_V R_{VS} + \beta R_{UV} + \gamma |R_{US} - R_{VS}|$ ;

## Алгоритм Ланса-Уильямса для частичного обучения

Алгоритм иерархической кластеризации (Ланс, Уильямс, 1967):  
итеративный пересчёт расстояний  $R_{UV}$  между кластерами  $U, V$ .

$C_1 := \{\{x_1\}, \dots, \{x_\ell\}\}$  — все кластеры 1-элементные;

$R_{\{x_i\}\{x_j\}} := \rho(x_i, x_j)$  — расстояния между ними;

**для всех**  $t = 2, \dots, \ell$  ( $t$  — номер итерации):

найти в  $C_{t-1}$  пару кластеров  $(U, V)$  с минимальным  $R_{UV}$ ,

**при условии,** что в  $U \cup V$  нет объектов с разными метками;

слить их в один кластер:

$W := U \cup V$ ;

$C_t := C_{t-1} \cup \{W\} \setminus \{U, V\}$ ;

**для всех**  $S \in C_t$

вычислить  $R_{WS}$  по формуле Ланса-Уильямса:

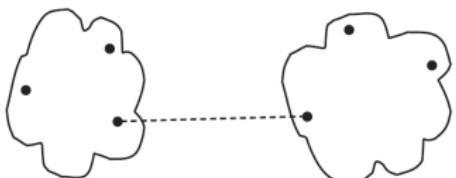
$R_{WS} := \alpha_U R_{US} + \alpha_V R_{VS} + \beta R_{UV} + \gamma |R_{US} - R_{VS}|$ ;

## Частные случаи формулы Ланса-Уильямса

### 1. Расстояние ближнего соседа:

$$R_{WS}^b = \min_{w \in W, s \in S} \rho(w, s);$$

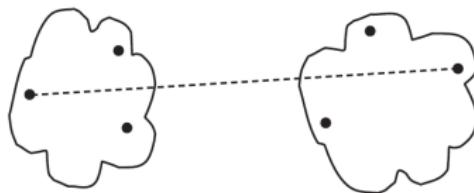
$$\alpha_U = \alpha_V = \frac{1}{2}, \quad \beta = 0, \quad \gamma = -\frac{1}{2}.$$



### 2. Расстояние дальнего соседа:

$$R_{WS}^d = \max_{w \in W, s \in S} \rho(w, s);$$

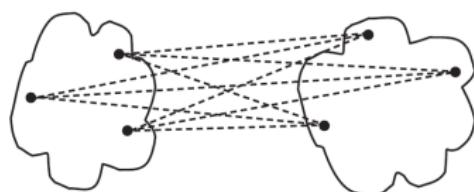
$$\alpha_U = \alpha_V = \frac{1}{2}, \quad \beta = 0, \quad \gamma = \frac{1}{2}.$$



### 3. Групповое среднее расстояние:

$$R_{WS}^g = \frac{1}{|W||S|} \sum_{w \in W} \sum_{s \in S} \rho(w, s);$$

$$\alpha_U = \frac{|U|}{|W|}, \quad \alpha_V = \frac{|V|}{|W|}, \quad \beta = \gamma = 0.$$



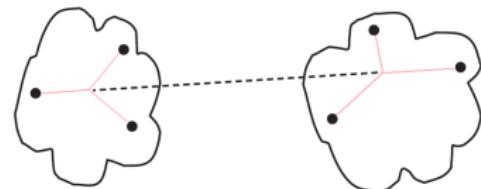
## Частные случаи формулы Ланса-Уильямса

### 4. Расстояние между центрами:

$$R_{WS}^u = \rho^2 \left( \sum_{w \in W} \frac{w}{|W|}, \sum_{s \in S} \frac{s}{|S|} \right);$$

$$\alpha_U = \frac{|U|}{|W|}, \quad \alpha_V = \frac{|V|}{|W|},$$

$$\beta = -\alpha_U \alpha_V, \quad \gamma = 0.$$



### 5. Расстояние Уорда:

$$R_{WS}^y = \frac{|S||W|}{|S|+|W|} \rho^2 \left( \sum_{w \in W} \frac{w}{|W|}, \sum_{s \in S} \frac{s}{|S|} \right);$$

$$\alpha_U = \frac{|S|+|U|}{|S|+|W|}, \quad \alpha_V = \frac{|S|+|V|}{|S|+|W|}, \quad \beta = \frac{-|S|}{|S|+|W|}, \quad \gamma = 0.$$

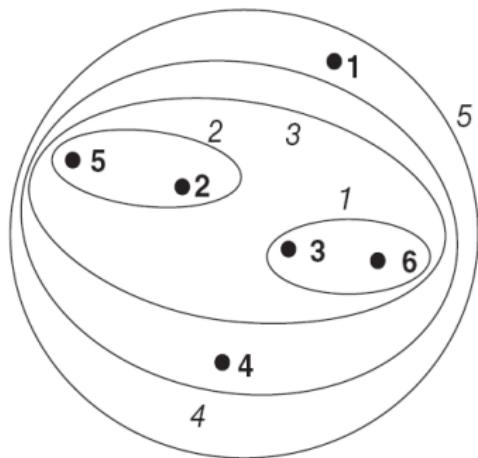
## Проблема выбора

Какая функция расстояния лучше?

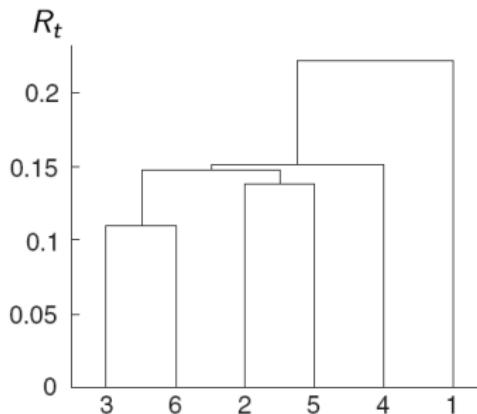
## Визуализация кластерной структуры

### 1. Расстояние ближнего соседа:

Диаграмма вложения



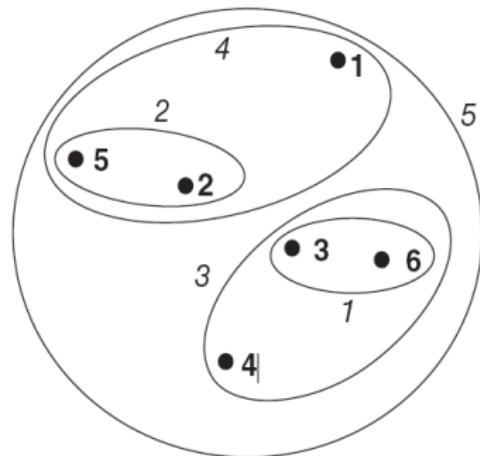
Дендрограмма



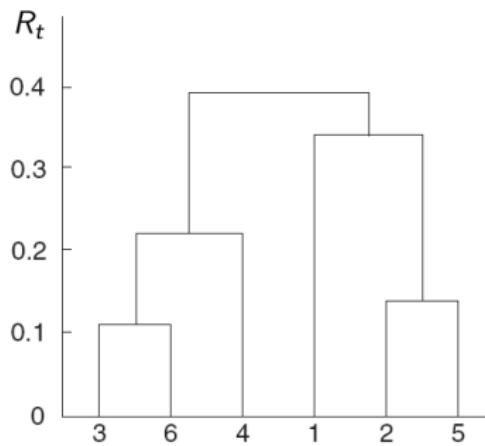
## Визуализация кластерной структуры

### 2. Расстояние дальнего соседа:

Диаграмма вложения



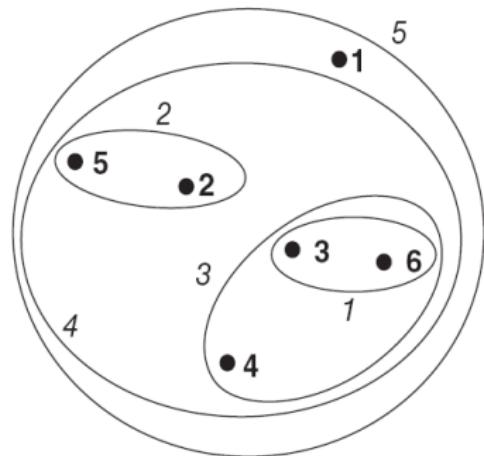
Дендрограмма



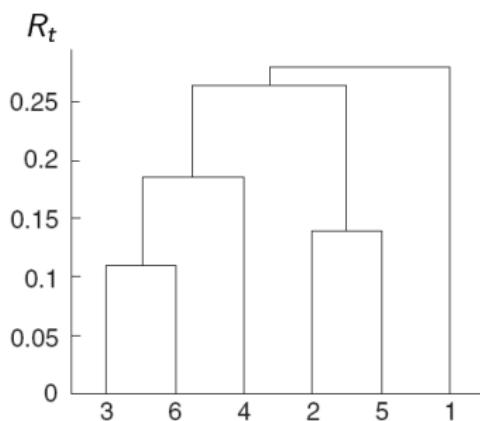
## Визуализация кластерной структуры

### 3. Групповое среднее расстояние:

Диаграмма вложения



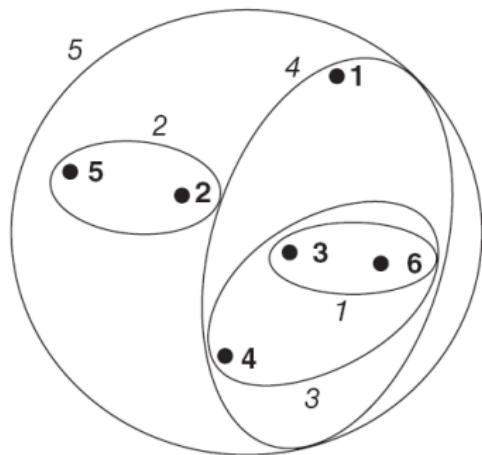
Дендрограмма



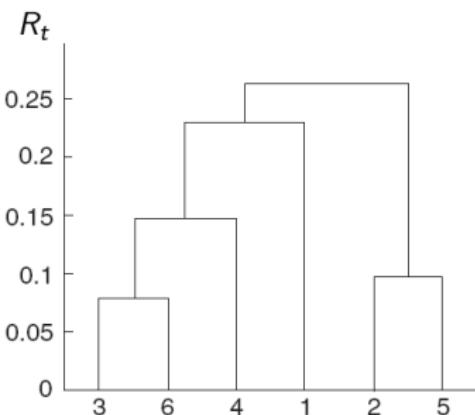
## Визуализация кластерной структуры

### 5. Расстояние Уорда:

Диаграмма вложения

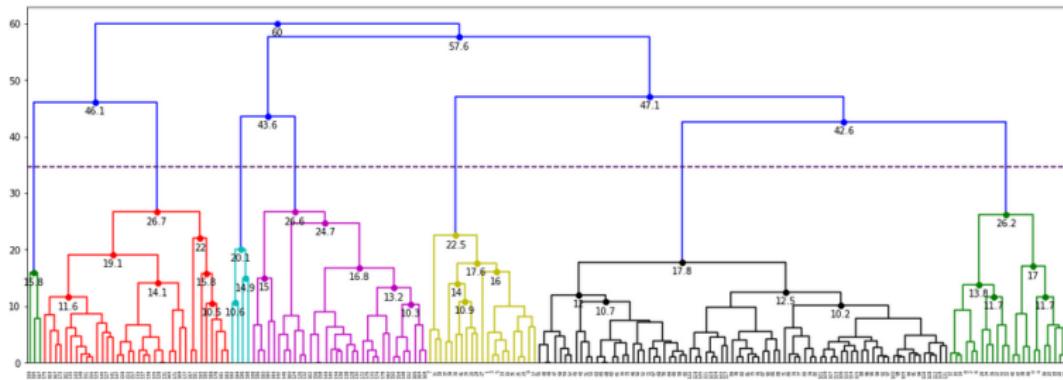


Дендрограмма



## Дендрограмма — визуализация иерархической кластеризации

- Кластеры группируются вдоль горизонтальной оси
- По вертикальной оси откладываются расстояния  $R_t$
- Расстояния возрастают, линии нигде не пересекаются
- Верхние уровни различимы лучше, чем нижние
- Уровень отсечения определяет число кластеров



## Основные свойства иерархической кластеризации

- *Монотонность*: дендрограмма не имеет самопересечений, при каждом слиянии расстояние между объединяемыми кластерами только увеличивается:  $R_2 \leq R_3 \leq \dots \leq R_\ell$ .
- *Сжимающее расстояние*:  $R_t \leq \rho(\mu_U, \mu_V), \forall t$ .
- *Растягивающее расстояние*:  $R_t \geq \rho(\mu_U, \mu_V), \forall t$

### Теорема (Миллиган, 1979)

Кластеризация монотонна, если выполняются условия

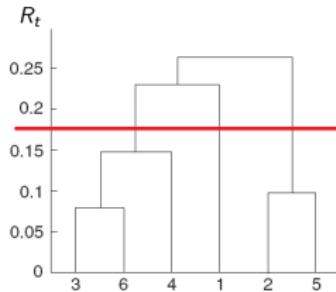
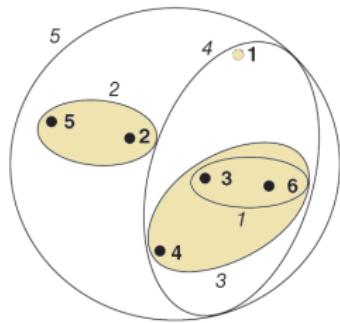
$$\alpha_U \geq 0, \quad \alpha_V \geq 0, \quad \alpha_U + \alpha_V + \beta \geq 1, \quad \min\{\alpha_U, \alpha_V\} + \gamma \geq 0.$$

$R^C$  не монотонно;  $R^6$ ,  $R^d$ ,  $R^r$ ,  $R^y$  — монотонны.

$R^6$  — сжимающее;  $R^d$ ,  $R^y$  — растягивающие;

## Рекомендации и выводы

- рекомендуется пользоваться расстоянием Уорда  $R^y$ ;
- обычно строят несколько вариантов и выбирают лучший визуально по дендрограмме;
- определение числа кластеров — по максимуму  $|R_{t+1} - R_t|$ , тогда результирующее множество кластеров :=  $C_t$ .



## Метод частичного обучения self-training (1965-1970)

Пусть  $\mu: X^k \rightarrow a$  — метод обучения классификации;  
классификаторы имеют вид  $a(x) = \arg \max_{y \in Y} \Gamma_y(x)$ ;

Псевдоотступ — степень уверенности классификации  $a_i = a(x_i)$ :

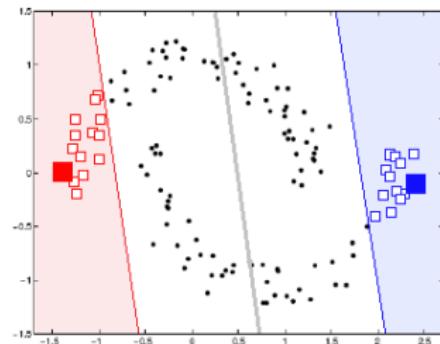
$$M_i(a) = \Gamma_{a_i}(x_i) - \max_{y \in Y \setminus a_i} \Gamma_y(x_i).$$

**Алгоритм self-training** — обёртка (wrapper) над методом  $\mu$ :

```

 $Z := X^k;$ 
пока  $|Z| < \ell$ 
   $a := \mu(Z);$ 
   $\Delta := \{x_i \in U \setminus Z \mid M_i(a) \geq M_0\};$ 
   $a_i := a(x_i)$  для всех  $x_i \in \Delta;$ 
   $Z := Z \cup \Delta;$ 

```



$M_0$  можно определять, например, из условия  $|\Delta| = 0.05 |U|$

## Метод частичного обучения co-training (Blum, Mitchell, 1998)

Пусть  $\mu_1: X^k \rightarrow a_1$ ,  $\mu_2: X^k \rightarrow a_2$  — два существенно различных метода обучения, использующих

- либо разные наборы признаков;
- либо разные парадигмы обучения (inductive bias);
- либо разные источники данных  $X_1^{k_1}$ ,  $X_2^{k_2}$ .

$$Z_1 := X_1^{k_1}; \quad Z_2 := X_2^{k_2};$$

**пока**  $|Z_1 \cup Z_2| < \ell$

$$a_1 := \mu_1(Z_1); \quad \Delta_1 := \{x_i \in U \setminus Z_1 \setminus Z_2 \mid M_i(a_1) \geq M_{01}\};$$

$a_i := a_1(x_i)$  для всех  $x_i \in \Delta_1$ ;

$$Z_2 := Z_2 \cup \Delta_1;$$

$$a_2 := \mu_2(Z_2); \quad \Delta_2 := \{x_i \in U \setminus Z_1 \setminus Z_2 \mid M_i(a_2) \geq M_{02}\};$$

$a_i := a_2(x_i)$  для всех  $x_i \in \Delta_2$ ;

$$Z_1 := Z_1 \cup \Delta_2;$$

## Метод частичного обучения co-learning (deSa, 1993)

Пусть  $\mu_t: X^k \rightarrow a_t$  — разные методы обучения,  $t = 1, \dots, T$ .

**Алгоритм co-learning** — это self-training для композиции — простого голосования базовых алгоритмов  $a_1, \dots, a_T$ :

$$a(x) = \arg \max_{y \in Y} \Gamma_y(x), \quad \Gamma_y(x_i) = \sum_{t=1}^T [a_t(x_i) = y].$$

тогда  $M_i(a)$  — степень уверенности классификации  $a(x_i)$ .

```
Z := X^k;  
пока |Z| < ℓ  
    a := μ(Z);  
    Δ := {x_i ∈ U \ Z | M_i(a) ≥ M₀};  
    a_i := a(x_i) для всех x_i ∈ Δ;  
    Z := Z ∪ Δ;
```

## Общий оптимизационный подход к задачам SSL

**Дано:**

$X^k = \{x_1, \dots, x_k\}$  — размеченные объекты (labeled data);  
 $\{y_1, \dots, y_k\}$

$U = \{x_{k+1}, \dots, x_\ell\}$  — неразмеченные объекты (unlabeled data).

**Найти:** модель классификации  $a(x, w)$

**Критерий** одновременной классификации и кластеризации:

$$\underbrace{\sum_{i=1}^k \mathcal{L}(a(x_i, w), y_i)}_{\text{классификация}} + \lambda \underbrace{\sum_{i=1}^\ell \mathcal{L}_U(a(x_i, w))}_{\text{кластеризация}} \rightarrow \min_w$$

где  $\mathcal{L}(a, y)$  — функция потерь классификации,  
 $\mathcal{L}_U(a)$  — функция потерь для неразмеченных данных

## Напоминание: SVM для двухклассовой классификации

Линейный классификатор на два класса  $Y = \{-1, 1\}$ :

$$a(x) = \text{sign}(\langle w, x \rangle - w_0), \quad w, x \in \mathbb{R}^n, \quad w_0 \in \mathbb{R}.$$

Отступ объекта  $x_i$ :

$$M_i(w, w_0) = (\langle w, x_i \rangle - w_0)y_i.$$

Задача обучения весов  $w, w_0$  по размеченной выборке:

$$Q(w, w_0) = \sum_{i=1}^k (1 - M_i(w, w_0))_+ + \frac{1}{2C} \|w\|^2 \rightarrow \min_{w, w_0} .$$

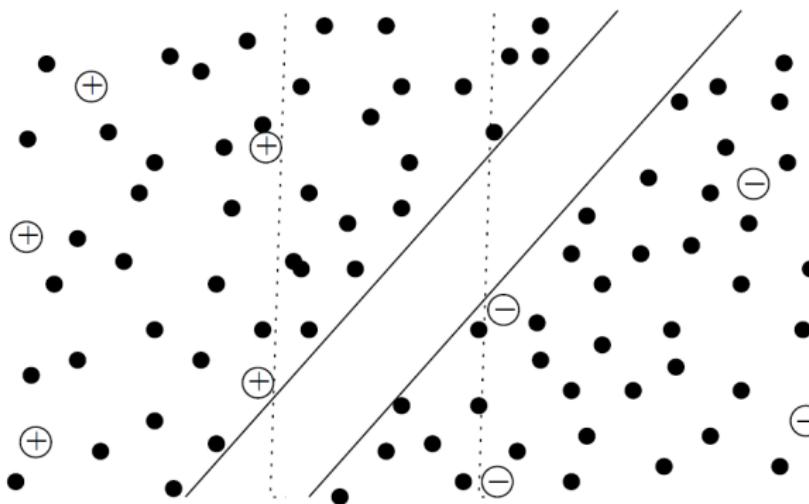
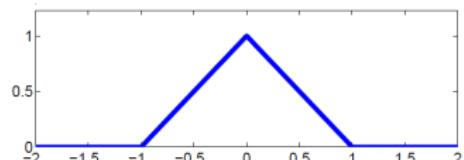
Функция  $\mathcal{L}(M) = (1 - M)_+$  штрафует за уменьшение отступа.

Идея!

Функция  $\mathcal{L}(M) = (1 - |M|)_+$  штрафует за попадание объекта внутрь разделяющей полосы.

## Функция потерь для трансдуктивного SVM

Функция потерь  $\mathcal{L}(M) = (1 - |M|)_+$   
штрафует за попадание объекта  
внутрь разделяющей полосы.



## Метод частичного обучения Transductive SVM

Обучение весов  $w, w_0$  по частично размеченной выборке:

$$Q(w, w_0) = \sum_{i=1}^k (1 - M_i(w, w_0))_+ + \frac{1}{2C} \|w\|^2 + \\ + \gamma \sum_{i=k+1}^{\ell} (1 - |M_i(w, w_0)|)_+ \rightarrow \min_{w, w_0} .$$

Достоинства и недостатки TSVM:

- ⊕ как и в обычном SVM, можно использовать ядра;
- ⊕ имеются эффективные реализации для больших данных;
- ⊖ задача невыпуклая, методы оптимизации сложнее;
- ⊖ решение неустойчиво, если нет области разреженности;
- ⊖ требуется настройка двух параметров  $C, \gamma$ ;

## Напоминание: многоклассовая логистическая регрессия

Линейный классификатор по конечному множеству классов  $|Y|$ :

$$a(x) = \arg \max_{y \in Y} \langle w_y, x \rangle, \quad x, w_y \in \mathbb{R}^n.$$

Вероятность того, что объект  $x_i$  относится к классу  $y$ :

$$P(y|x_i, w) = \frac{\exp \langle w_y, x_i \rangle}{\sum_{c \in Y} \exp \langle w_c, x_i \rangle}.$$

Задача максимизации регуляризованного правдоподобия:

$$Q(w) = \sum_{i=1}^k \log P(y_i|x_i, w) - \frac{1}{2C} \sum_{y \in Y} \|w_y\|^2 \rightarrow \max_w,$$

Оптимизация  $Q(w)$  — методом стохастического градиента, по  $n|Y|$ -мерному вектору параметров  $w = (w_y : y \in Y)$ .

## Согласование модели на размеченных и неразмеченных данных

Теперь учтём неразмеченные данные  $U = \{x_{k+1}, \dots, x_\ell\}$ .

Пусть  $b_j(x)$  — бинарные признаки,  $j = 1, \dots, m$ .

Оценим вероятности  $P(y|b_j(x) = 1)$  двумя способами:

1) эмпирическая оценка по размеченным данным  $X^k$ :

$$\hat{p}_j(y) = \frac{\sum_{i=1}^k b_j(x_i)[y_i = y]}{\sum_{i=1}^k b_j(x_i)};$$

2) оценка по неразмеченным данным  $U$  и вероятностной модели:

$$p_j(y|w) = \frac{\sum_{i=k+1}^\ell b_j(x_i)P(y|x_i, w)}{\sum_{i=k+1}^\ell b_j(x_i)}.$$

Максимизируем правдоподобие вероятностной модели  $p_j(y|w)$ ,  
приближающей эмпирическое распределение  $\hat{p}_j(y)$ .

## Построение регуляризатора (XR, eXpectation Regularization)

Логарифм правдоподобия модели классов по  $j$ -му признаку:

$$L_j(w) = \sum_{y \in Y} \hat{p}_j(y) \log p_j(y|w) \rightarrow \max_w.$$

Регуляризация критерия  $Q(w)$  суммой log-правдоподобий  $L_j(w)$  с коэффициентом регуляризации  $\gamma$ :

$$\begin{aligned} Q(w) + \gamma \sum_{j=1}^m L_j(w) &= \sum_{i=1}^k \log P(y_i|x_i, w) - \frac{1}{2C} \sum_{y \in Y} \|w_y\|^2 + \\ &+ \gamma \sum_{j=1}^m \sum_{y \in Y} \hat{p}_j(y) \log \left( \sum_{i=k+1}^{\ell} b_j(x_i) P(y|x_i, w) \right) \rightarrow \max_w. \end{aligned}$$

---

Mann, McCallum. Simple, robust, scalable semi-supervised learning via expectation regularization. ICML 2007.

## Особенности метода XR (eXpectation Regularization)

- ➊ XR — это SSL, но это вообще не кластеризация!
- ➋ Оптимизация методом стохастического градиента.
- ➌ Возможные варианты задания переменных  $b_j$ :
  - $b_j(x) \equiv 1$ , тогда  $P(y|b_j(x) = 1)$  — априорная вероятность класса  $y$  (label regularization)
    - подходит для задач с несбалансированными классами;
  - $b_j(x) = [$ термин  $j$  содержится в тексте  $x$  $]$ 
    - подходит для задач классификации текстов.
- ➍ метод слабо чувствителен к выбору  $C$  и  $\gamma$ ,
- ➎ устойчив к погрешностям оценивания  $\hat{p}_j(y)$ ,
- ➏ не требует большого числа размеченных объектов  $k$ ,
- ➐ хорошо подходит для категоризации текстов.

---

Mann, McCallum. Simple, robust, scalable semi-supervised learning via expectation regularization. ICML 2007.

## Резюме в конце лекции

- Кластеризация — это обучение без учителя, некорректно поставленная задача, существует много оптимизационных и эвристических алгоритмов кластеризации
- DBSCAN — популярный быстрый алгоритм кластеризации
- Задача SSL занимает промежуточное положение между классификацией и кластеризацией, но не сводится к ним.
- Методы кластеризации легко адаптируются к SSL путём введения ограничений (constrained clustering).
- Адаптация методов классификации реализуется сложнее, но приводит к более эффективным методам.
- Регуляризация объединяет критерии на размеченных и неразмеченных данных в одну задачу оптимизации.