

# *Кластеризация данных*

Курс «Основы анализа текстовых данных»

Кафедра управления и интеллектуальных технологий

НИУ «МЭИ»

Весна 2023 г.

# *Что такое кластеризация?*

**Кластеризация** - задача разбиения заданной выборки *объектов* на непересекающиеся подмножества, называемые *кластерами*, так, чтобы каждый кластер состоял из схожих объектов, а объекты разных кластеров существенно отличались.

Под схожестью обычно понимается близость друг к другу относительно выбранной метрики.

Задача кластеризации относится к разделу задач обучения без учителя.

**Обучение без учителя** (Unsupervised learning) — один из разделов машинного обучения. Изучает широкий класс задач обработки данных, в которых известны только описания множества объектов (обучающей выборки), и требуется обнаружить внутренние взаимосвязи, зависимости, закономерности, существующие между объектами.

Обучение без учителя часто противопоставляется обучению с учителем, когда для каждого обучающего объекта задаётся «правильный ответ», и требуется найти зависимость между объектами и ответами.

# *Постановка задачи кластеризации*

**Дано:**

$X$  – пространство объектов

$\vec{X}_l$  – обучающая выборка;  $l = 1 \dots L$

$\rho$  - функция расстояния между объектами

**Найти:**

$Y$  – множество кластеров и

а:  $X \rightarrow Y$  – алгоритм кластеризации, такой, что:

- каждый кластер состоит из близких объектов
- объекты разных кластеров существенно различны

# *Особенности задачи кластеризации*

Решение задачи кластеризации принципиально неоднозначно:

- Точной постановки задачи кластеризации нет
- Существует множество критериев качества кластеризации
- Число кластеров  $|Y|$  заранее, как правило, не известно
- Результат кластеризации существенно зависит от метрики  $\rho$ , которую эксперт задает субъективно

# Цели кластеризации


**Понимание данных путём выявления кластерной структуры.** Разбиение выборки на группы схожих объектов позволяет упростить дальнейшую обработку данных и принятия решений, применяя к каждому кластеру свой метод анализа (стратегия «разделяй и властвуй»).

**Сжатие данных.** Если исходная выборка избыточно большая, то можно сократить её, оставив по одному наиболее типичному представителю от каждого кластера.

**Обнаружение новизны** (novelty detection). Выделяются нетипичные объекты, которые не удается присоединить ни к одному из кластеров.

**Построение иерархии множества объектов** (задача таксономии)


# Примеры кластерных структур



внутрикластерные расстояния, как правило,  
меньше межклластерных



ленточные кластеры



кластеры с центром

# Примеры кластерных структур




кластеры могут соединяться перемычками

кластеры могут накладываться на разреженный фон из редко расположенных объектов

кластеры могут перекрываться

# Примеры 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 не имеет формального определения

# Проблема чувствительности к метрике



А – девушки  
В – молодые люди



После перенормировки  
(сжали ось «Вес» вдвое)

# Качество кластеризации

**Сумма средних внутрикластерных расстояний:**

$$F_0 = \sum_{k \in Y} \frac{1}{N_k} \sum_{l=1}^{N_k} \rho(\vec{X}_l, \mu_k) \rightarrow \min$$

**Сумма межкластерных расстояний:**


$$F_1 = \sum_{j,k \in Y} \rho(\mu_j, \mu_k) \rightarrow \max$$

**Обобщенный функционал:**

$$F_2 = \frac{F_0}{F_1} \rightarrow \min$$

$\mu_k$  - Центр масс кластера k

$N_k$  - Размер кластера k



# Качество кластеризации

**Коэффициент силуэта**

$$s_i = \frac{b_i - a_i}{\max(a_i, b_i)}$$

Среднее расстояние между i-м и остальными объектами кластера – **cohesion**

$$a_i = \frac{1}{|C_I| - 1} \sum_{j \in C_I, i \neq j} d(i, j)$$

Минимальное расстояние между i-м и остальными объектами других кластеров – **separation**

$$b_i = \min_{I \neq J} \frac{1}{|C_J|} \sum_{j \in C_J} d(i, j)$$


Для каждого объекта рассчитываются значения  $s_i$ .

$s_i \rightarrow 1$  – высокая уверенность в принадлежности объекта кластеру


$s_i \rightarrow -1$  – объект больше подходит другому кластеру.

Среднее  $s_i$  характеризует кластеризацию в целом.

Графическое отображение:




# Качество кластеризации




[https://scikit-learn.org/stable/auto\\_examples/cluster/plot\\_kmeans\\_silhouette\\_analysis.html](https://scikit-learn.org/stable/auto_examples/cluster/plot_kmeans_silhouette_analysis.html)


# Качество кластеризации




# Качество кластеризации



# Качество кластеризации




# Качество кластеризации



# *Качество кластеризации*

В задачах кластеризации текстов качество кластеризации можем косвенно оценить по наиболее частотным терминам, встречающимся в классе («Облако слов»). Т.е. мы могли бы дать название каждому кластеру исходя из наиболее частотных терминов :



# *Алгоритмы кластеризации*

## Иерархические

- Агломеративная кластеризация
- Дивизимная кластеризация

## Статистические

- EM-алгоритмы
- К-средних (k-means)
- Алгоритм FOREL

## Самоорганизующиеся карты - сети Кохонена

# Иерархические алгоритмы кластеризации

Среди алгоритмов иерархической кластеризации различаются два основных типа. Дивизимные или нисходящие алгоритмы разбивают выборку на всё более и более мелкие кластеры. Более распространены агломеративные или восходящие алгоритмы, в которых объекты объединяются во всё более и более крупные кластеры

Сначала каждый объект считается отдельным кластером. Для одноэлементных кластеров естественным образом определяется функция расстояния  $\rho(x_j, x_k)$

Затем запускается процесс слияний. На каждой итерации вместо пары самых близких кластеров  $U$  и  $V$  образуется новый кластер  $W = U \cup V$

Расстояние от нового кластера  $W$  до любого другого кластера  $S$  вычисляется по расстояниям  $R(U, V)$ ,  $R(U, S)$  и  $R(V, S)$ :

$$R(U \cup V, S) = \alpha_u R(U, S) + \alpha_v R(V, S) + \beta R(U, V) + \gamma |R(U, S) - R(V, S)|$$

где  $\alpha_u, \alpha_v, \beta, \gamma$ - числовые параметры

Эта универсальная формула обобщает практически все разумные способы определить расстояние между кластерами. Она была предложена Лансом и Уильямсом в 1967 году.

# Иерархические алгоритмы кластеризации

На практике используются следующие способы вычисления расстояний  $R(W, S)$  между кластерами  $W$  и  $S$ . Для каждого из них доказано соответствие формуле Ланса-Вильямса при определённых сочетаниях параметров:

Расстояние ближнего соседа (single linkage):

$$R^b(W, S) = \min_{w \in W, s \in S} \rho(w, s); \quad \alpha_u = \alpha_v = \frac{1}{2}, \quad \beta = 0, \quad \gamma = -\frac{1}{2}$$

Расстояние дальнего соседа (complete linkage):

$$R^d(W, S) = \max_{w \in W, s \in S} \rho(w, s); \quad \alpha_u = \alpha_v = \frac{1}{2}, \quad \beta = 0, \quad \gamma = \frac{1}{2}$$

Расстояние до центра:

$$R^c(W, S) = \rho^2 \left( \sum_{w \in W} \frac{w}{|W|}, \sum_{s \in S} \frac{s}{|S|} \right); \quad \alpha_u = \frac{|U|}{|W|}, \quad \alpha_v = \frac{|V|}{|W|}, \quad \beta = -\alpha_u \alpha_v, \quad \gamma = 0$$


Расстояние Уорда (Варда, Ward):

$$R^y(W, S) = \frac{|S||W|}{|S| + |W|} \rho^2 \left( \sum_{w \in W} \frac{w}{|W|}, \sum_{s \in S} \frac{s}{|S|} \right); \quad \alpha_u = \frac{|S| + |U|}{|S| + |W|}, \quad \alpha_v = \frac{|S| + |V|}{|S| + |W|}, \quad \beta = -\frac{|S|}{|S| + |W|}, \quad \gamma = 0$$


# Иерархические алгоритмы кластеризации

Расстояние ближнего соседа

Диаграмма вложения




Дендрограмма




# Иерархические алгоритмы кластеризации

Расстояние дальнего соседа

Диаграмма вложения




Дендрограмма




# Иерархические алгоритмы кластеризации

Расстояние Уорда

Диаграмма вложения



Дендрограмма



# Основные свойства иерархической кластеризации

**Монотонность:** дендрограмма не имеет самопересечений, при каждом слиянии расстояние между объединяемыми кластерами увеличивается:  $R_2 \leq R_3 \leq R_4 \dots$

$R^{\text{ц}}$  – не монотонна,  $R^{\text{б}}$   $R^{\text{д}}$   $R^{\text{у}}$  – монотонны

**Сжимаемость и растягиваемость:**

$R_t \leq \rho(\mu_u, \mu_v), \forall t$  – сжимающее расстояние



$R_t \geq \rho(\mu_u, \mu_v), \forall t$  – растягивающее расстояние

Свойство растяжения желательно, так как оно способствует более четкому отделению кластеров

$R^{\text{б}}$  – сильно сжимающее,  $R^{\text{д}}$   $R^{\text{у}}$  – растягивающие,  $R^{\text{ц}}$  – сохраняет метрику пространства

## Выводы и рекомендации

- Рекомендуется пользоваться расстоянием Уорда.
- Обычно строят несколько вариантов и выбирают лучший визуально по дендрограмме.
- Определять число кластеров рекомендуется по максимальной высоте участка  $|R_{t+1} - R_t|$  на дендрограмме.



# EM-алгоритм. Предпосылки

**Гипотеза о вероятностной природе данных:**

Обучающая выборка  $X$  случайна и независима, состоит из смеси распределений

$$p(x) = \sum_{y \in Y} w_y p_y(x) \quad \sum_{y \in Y} w_y = 1$$

$p_y(x)$  – функция плотности распределения кластера  $y$ ,

$w_y$  - априорная вероятность появления объектов из кластера  $y$

**Гипотеза о пространстве объектов и форме кластеров:**

Кластеры  $n$ -мерные, гауссовские

$$p_y(x) = (2\pi)^{-n/2} (\sigma_{y1} \cdots \sigma_{yn})^{-1} \exp(-\frac{1}{2} \rho_y^2(x, \mu_y))$$

$\mu_y = (\mu_{y1}, \dots, \mu_{yn})$  – центр кластера  $y$

$\Sigma_y = \text{diag}(\sigma_{y1}^2, \dots, \sigma_{yn}^2)$  – диагональная матрица ковариаций  $\Rightarrow$  дисперсии

$$\rho_y^2(x, x') = \sum_{j=1}^n \sigma_{yj}^{-2} |x_j - x'_j|^2$$

# EM-алгоритм

1: начальное приближение  $w_y, \mu_y, \Sigma_y$  для всех  $y \in Y$ ;

2: **повторять**

3: Е-шаг (expectation):

$$g_{iy} := P(y|x_i) \equiv \frac{w_y p_y(x_i)}{\sum_{z \in Y} w_z p_z(x_i)}, \quad y \in Y, \quad i = 1, \dots, \ell;$$

4: М-шаг (maximization):

$$w_y := \frac{1}{\ell} \sum_{i=1}^{\ell} g_{iy}, \quad y \in Y;$$

$$\mu_{yj} := \frac{1}{\ell w_y} \sum_{i=1}^{\ell} g_{iy} x_{ij}, \quad y \in Y, \quad j = 1, \dots, n;$$

$$\sigma_{yj}^2 := \frac{1}{\ell w_y} \sum_{i=1}^{\ell} g_{iy} (x_{ij} - \mu_{yj})^2, \quad y \in Y, \quad j = 1, \dots, n;$$


5:  $y_i := \arg \max_{y \in Y} g_{iy}, \quad i = 1, \dots, \ell;$

6: **пока**  $y_i$  не перестанут изменяться;

**На Е-шаге** по формуле Байеса  
расчитываются «скрытые переменные»  $g_{iy}$  –  
апостериорная вероятность того, что  $i$ -й  
объект принадлежит кластеру  $y$

**На М-шаге** уточняются параметры каждого  
кластера используя скрытые переменные  $g_{iy}$

# EM-алгоритм



# Метод $k$ -средних ( $k$ -means)

Упрощенный аналог ЕМ-алгоритма:  
Жесткая кластеризация вместо мягкой

1. Начальное приближение центроидов  $\mu_y, \ y \in Y$

**2. Повторять:**

3. Аналог Е-шага:

отнести каждый  $x_i$  к ближайшему центру

$$y_i := \arg \min_{y \in Y} \rho(x_i, \mu_y), \quad i = 1, \dots, \ell;$$

4. Аналог М-шага:


вычислить новые положения центров:

$$\mu_{yd} := \frac{\sum_{i=1}^{\ell} [y_i = y] f_d(x_i)}{\sum_{i=1}^{\ell} [y_i = y]}, \quad y \in Y, \quad d = 1, \dots, n;$$

5. Пока  $y_i$  не перестанут изменяться

# Недостатки метода (*k-means*)

- Не гарантируется достижение глобального минимума суммарного квадратичного отклонения  $V$ , а только одного из локальных минимумов.
- Результат зависит от выбора исходных центров кластеров, их оптимальный выбор неизвестен.
- Рекомендуется повторная прогонка алгоритма для избежания ситуации «плохой» кластеризации.
- Число кластеров надо знать заранее или перебирать в поисках оптимального.



# Семейство алгоритмов FOREL (ФОРмальный Элемент)

Алгоритм предложен Загоруйко Н. Г. и Ёлкиной В. Н. в 1967 году.

Задается параметр  $R$  – радиус поиска локальных сгущений.








На каждом шаге мы

1. случайным образом выбираем объект из выборки,
2. раздуваем вокруг него сферу радиуса  $R$ ,
3. внутри этой сферы выбираем центр тяжести и делаем его центром новой сферы.

Таким образом, мы на каждом шаге двигаем сферу в сторону локального сгущения объектов выборки, т.е. стараемся захватить как можно больше объектов выборки сферой фиксированного радиуса.

4. После того как центр сферы стабилизируется, все объекты внутри сферы с этим центром мы помечаем как кластеризованные и выкидываем их из выборки. Этот процесс мы повторяем до тех пор, пока вся выборка не будет кластеризована.

# Визуализация алгоритма семейства FOREL



# *Свойства алгоритма FOREL*

Преимущества:

- Точность минимизации функционала качества (при удачном подборе параметра R)
- Наглядность визуализации кластеризации
- Сходимость алгоритма
- Возможность подсчета промежуточных функционалов качества, например, длины цепочки локальных сгущений


Недостатки:

- Относительно низкая производительность
- Плохая применимость алгоритма при плохой разделимости выборки на кластеры
- Неустойчивость алгоритма (зависимость от выбора начального объекта)
- Произвольное по количеству разбиение на кластеры
- Необходимость априорных знаний о ширине (диаметре) кластеров

# DBSCAN

Density-based spatial clustering of applications with noise, плотностной алгоритм пространственной кластеризации с присутствием шума

- $p$  - «базовая» точка, если в  $\epsilon$ -окрестности находится  $\text{minPts}$  соседей.
- точка  $q$  прямо достижима из  $p$ , если находится на расстоянии не больше  $\epsilon$
- точка  $r$  достижима из  $p$ , если к ней имеется путь прямо достижимых точек
- все точки, не достижимые из базовых являются выбросами
- все точки, достижимые из  $p$ , но не имеющие  $\text{minPts}$  соседей – края кластера
- Если точка  $p$  является базовой, то она формирует кластер со всеми достижимыми из нее точками.



# DBSCAN

Гиперпараметры:

- $\epsilon$  – радиус поиска локальных сгущений (соседства)
- minPts – минимальное количество соседей для образования кластера

Достоинства

- Хорошо справляется с большим объемом данных
- Хорошо работает с кластерами произвольной формы и размера
- Позволяет находить выбросы
- Количество кластеров определяется в процессе алгоритма

Недостатки

- Кластеры должны быть отделены друг от друга или, как минимум, иметь разреженное межкластерное пространство

# *Самоорганизующиеся карты Кохонена*

Самоорганизующаяся карта Кохонена (Self-Organizing Map, SOM) – модель искусственной нейронной сети, способной обучаться без учителя. Предложена в 1984 году Теуво Кохоненом.

Целью применения данной сети является поиск скрытых закономерностей в данных, основываясь на снижении размерности исходного пространства в пространство меньшей размерности (на практике чаще всего используется двумерное, по причине, в частности, удобной визуализации). При этом топология исходного пространства остается той же самой. В результате обучения данной модели получается решетка, состоящая из обученных нейронов, она же и называется "картой" исходного пространства.

# Самоорганизующиеся карты Кохонена. Алгоритм

**Дано:**

Выборка  $X$ , состоящая из объектов  $X_i = \{x_1, \dots, x_d\}$ ,  $i = 1 \dots N$ ,  $d$  – размерность данных. Размерность  $X = [d * N]$

$W$  – матрица весов нейронов размерностью  $[d * M]$ .  $W_j = \{w_1, \dots, w_d\}$   $M$  – количество нейронов.

$D (M * M)$  – матрица расстояний между нейронами в слое (топология нейронов). При этом, эта матрица – не то же самое, что  $|W_i - W_j|$ .


$\alpha, \gamma$  – показатели кооперации и затухания скорости обучения соответственно.

$E$  – количество эпох.

**Алгоритм:**


1. Инициализировать  $W$
2.  $E$  раз:
  1. Для каждого объекта  $X_i$  из  $X$ :
    1.  $p = \arg \min ||X_i - W_i||$  - находим ближайший нейрон к объекту
    2.  $\forall j: w_j = w_j + \mu h_{p,j}(x - w_j)$
    3.  $\forall j: h_{p,j} = e^{D_{p,j}/\sigma(t)}$  - функция «растяжимости».  $t$  – зависимость от эпохи, например  $\sigma(t) = (\sigma^{-bt})$
  2.  $\mu = \mu^* \gamma$
  3.  $\sigma = \sigma^* \alpha$

# Самоорганизующиеся карты Кохонена. Топология сети




D – топология нейронов.

Не обязательно сетка, в общем случае – ограничивается фантазией, но в случае знания структуры выборки, должно выбираться удобным для визуализации.



# *U-matrix*

Для решения задачи кластеризации строится U-матрица – унифицированная матрица расстояний (unified distance matrix). Это разновидность визуализации карт Кохонена, где вместе со значениями нейронов показывается расстояние между ними. Таким образом можно легко определить, где кластеры соприкасаются, а где проходит граница.



Здесь черные точки – нейроны. Чем темнее ячейка, тем больше расстояние между данными нейронами в матрице  $W$  и соответственно, разрывами между объектами выборки  $X$ .  
Таким образом, светлые области можно рассматривать как кластеры, темные – как межкластерное пространство.