


Обучение без учителя.

- набор данных, объекты
  - нет объектов, для которых знает ответ.
- $f(\text{объект}) = \text{значение}$  ↗ объект  
↘ метр.

Если объект = текст, сами разбивает на кластеры (тема)

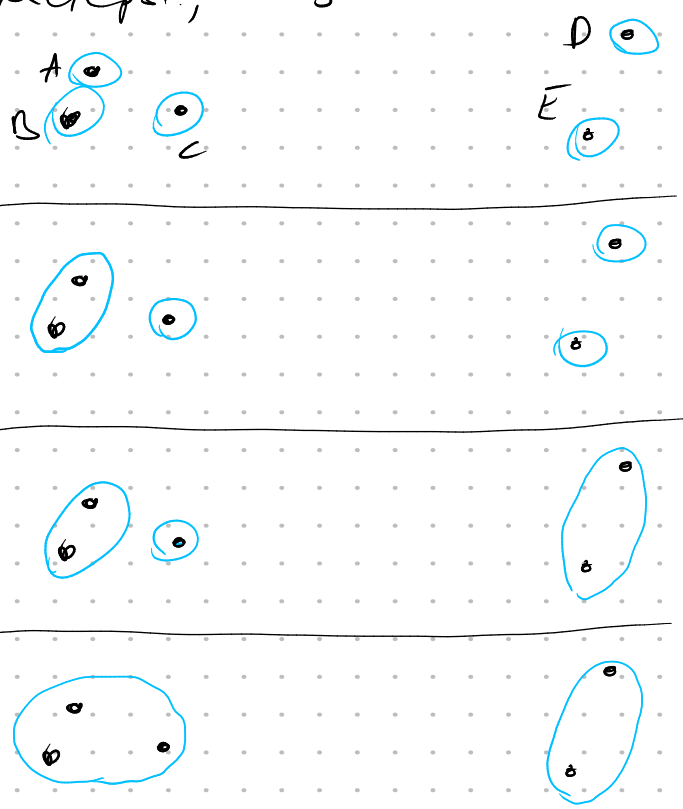
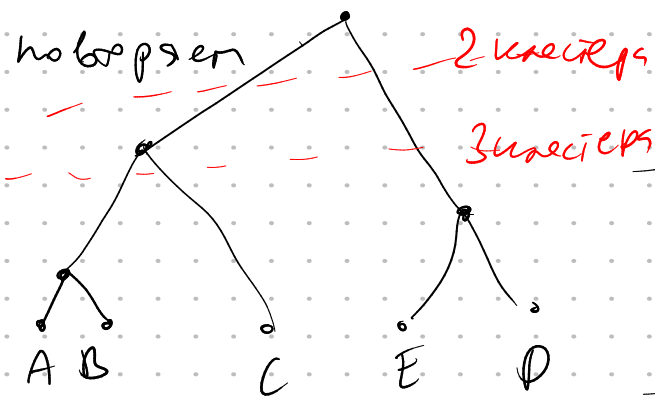
Потому что для объектов = точки кластеры - группы соседних точек.



### 1. Иерархическая кластеризация.

Начинаем с  $n$  точек, каждая точка = свой кластер


Находим самые близкие кластеры, объединяем



Когда остановим процесс, тогда и получили окончательные кластеры


либо заранее знаете, сколько хотите кластеров, либо в процессе работы алгоритма смотрите, не хотите ли остановить.

Расстояние между кластерами



Другие подходы - знаем, сколько кластеров хотим и сразу разбиваем на столько:

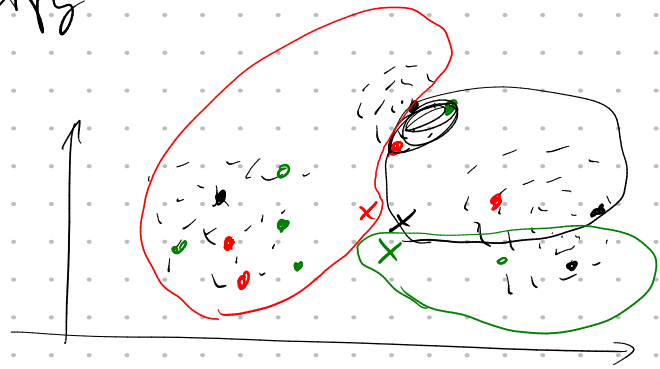
$k$ -средних




выбираем  $k$  случайных кластеров

находим центры, и переклассифицируем (каждый пункт и ближай. центру)

и т.д.



$J$  = количество кластеризации:  $\sum$  расстояния между кластерами  $\rightarrow$  min



Еще есть спектральные кластеризации.

Но у нас же кластеризуются документы / предложения

↑  
для автоматич. реферирования

/ слова.

Нужно уметь преобразовать doc / word / слова в точки (в  $\mathbb{R}^2$   $\mathbb{R}^{256}$   $\mathbb{R}^{100000}$ ).

Также отображения будут называться: векторизация embedding

Анализ документов в пространстве:

каждое значение в векторе — это одно слово

$c_{n1}$   $c_{n2}$  ...  $c_{nN}$  — все слова словаря

text1

text2


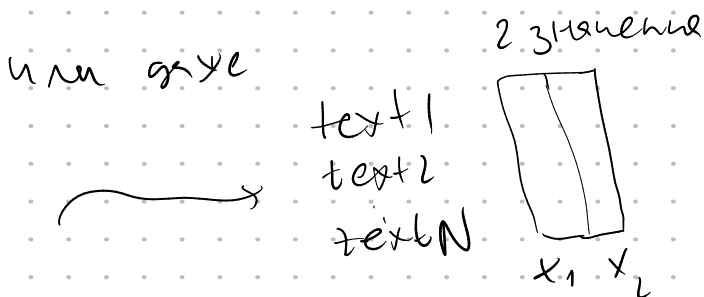


1) количество 10 5 0 0 0 0 1 — абсолютн.

2) частота 0.01 0.001 0 0 0 0 0.0002 — относит.

3) tf-idf =  $\underbrace{\text{частота слова}}_{\text{term frequency}} \cdot \underbrace{\frac{\text{общ. количество по слову}}{1}}_{\log(\text{doc freq} + 1)}$

...

Еще методы уменьшения размерности




# Примеры задач.

1. Кластеризация документов.



+ тематика их не известна.  
приведет к проблеме 2 методов  
PCA (principal components analysis)



критерии качества


1. в нем все сходится
- ✓ 2. в нем все сходится PCA  $\rightarrow 100$
3.  $\rightarrow 2$

2. Кластеризация предположений  
авторов. Соберёт ли  
в реальном разделение

из текстов двух  
результат кластеризации  
и авторов?

3. Документ. Кластеризация предположения.

Результат документа - это набор предположений по  
отношению к автору.



4. Смысловые слова.

Фонетическая структура

коса


- главные слова
- индикатор
- ...

цити - переменяется форма  
 - вычислитель  
 - красиво. вычитается  
 - :  
 - :

можно определить возможные смыслы абстрактным.

Корпус, все используемые слова:

применение слова



все применения одного слова можно классифицировать по контекстам. Классиф. = смысл.

как векторизовать контекст?

1) tf-idf.

2) word2vec (word2vec)

какие слова использовать?

1) "цити" - многозначное слово с разными смыслами

2) "коса" - разные смыслы  
"замол"

3) "Банан" + "шап" ← как было это одно слово

90 11:20