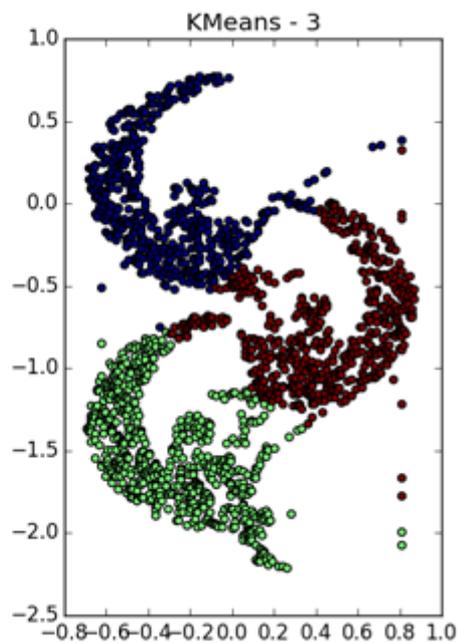


# Задача кластеризации данных



*Группа людей, действуя совместно, может свершить такое, о чем поодиночке они не могли бы и мечтать.*


*Франклин Рузвельт*

# Содержание

- **Основные концепции**
- **Разделительная кластеризация**
- Иерархическая кластеризация
- Плотностная кластеризация
- Нечеткая кластеризация
- Меры качества кластеризации

# Кластеризация





- Нахождение заранее неизвестных групп (*кластеров*) в множестве однотипных объектов, где объекты в одной группе существенно похожи, а объекты разных групп существенно отличны



# Применение кластеризации





- Понимание данных
  - Биология: иерархии живых организмов
  - Землепользование: нахождение в базе наблюдений Земли сходных территорий
  - Маркетинг: таргетирование клиентов
  - Городское планирование: группы похожих зданий
  - Изучение землетрясений: кластеризация эпицентров
- Предобработка данных
  - Редукция данных: замена группы объектов их центроидом
  - Удаление выбросов: нахождение объектов, наиболее удаленных от всех кластеров
  - Восстановление пропущенных данных: использование координат центроидов
  - Нахождение ближайших соседей: поиск среди объектов того же кластера

# Неоднозначность кластеризации: число групп



Сколько кластеров?

6



2

4

# Неоднозначность кластеризации


- Выбор функции расстояния (или меры схожести)
- Размерность данных
- Типы атрибутов
- Зависимости между атрибутами
- Распределение данных
- Наличие шумов и выбросов в данных

# Виды кластеризации

- **Эксклюзивная vs. инклюзивная**
  - Объект принадлежит одному или нескольким кластерам
- **Нечеткая vs. четкая**
  - Объект принадлежит каждому кластеру с некоторым весом (вероятностью), сумма весов равна 1
- **Частичная vs. полная**
  - Выполняется кластеризация части либо всего исходного множества объектов
- **Гетерогенная vs. гомогенная**
  - Допускается ли неоднородность в размерах, плотности и форме кластеров

# Хорошо отделимые кластеры

- Любой объект в кластере ближе (более похож) к любому другому объекту в кластере, чем к любому объекту вне данного кластера



**3 хорошо отделимых кластера**

# Центро-ориентированные кластеры





- Объект в кластере ближе (более похож) к «центру» кластера, чем к центру любого другого кластера
- Центр кластера
  - центроид: усреднение координат всех объектов в кластере
  - медоид: наиболее «репрезентативный» объект кластера



**4 центро-ориентированных кластера**

# Смежно-ориентированные кластеры


- Объект в кластере ближе (или более похож) к одному или нескольким другим объектам в кластере, чем к любому объекту вне кластера



**8 смежно-ориентированных кластеров**

# Плотностно-ориентированные кластеры


- Плотное скопление объектов, которое отделено скоплениями с низкой плотностью объектов от других скоплений с высокой плотностью
  - нерегулярные или переплетенные кластеры
  - шумы и выбросы




**6 плотностно-ориентированных кластеров**

# Концептуальные кластеры

- Объекты кластера имеют одно и то же свойство или выражают одну и ту же концепцию



**2 концептуальных кластера**




**2 концептуальных кластера**  
(точки в областях пересечения принадлежат обоим кластерам)

# Кластеры на базе целевой функции

- Объекты кластеров минимизируют или максимизируют целевую функцию
- Перечисление всех возможных способов разделения объектов на кластеры, оценка «качества» каждого набора кластеров заданной целевой функцией (NP-трудная задача)
- Глобальные или локальные цели
  - Иерархическая кластеризация: обычно локальные цели
  - Разделительная кластеризация: обычно глобальные цели
- Использование глобальной целевой функции: подогнать данные к параметризованной модели
  - Параметры модели определяются по данным
  - Модели смешивания предполагают, что данные представляют собой «смесь» ряда статистических распределений

# Кластеризация как задача из другой предметной области



Граф  $G(N, E, w)$

$$1. N = \bigcup_{i=1}^p N_i, \forall i \neq j N_i \cap N_j = \emptyset, p > 1$$

$$2. w(N_i) \approx \frac{w(N)}{p} \quad \forall i \in \{1, \dots, p\}$$

$$3. W_{cut} \rightarrow \min, W_{cut} = \sum_{e \in E_{cut}} w(e),$$


$$E_{cut} = \{(u, v) \in E \mid u \in N_i, v \in N_j, 1 \leq i, j \leq p, i \neq j\}$$

# Особенности, требования и вызовы кластеризации



- Масштабируемость
  - Быстродействие и возможность эффективного распараллеливания
- Умение работать с разными типами атрибутов
  - Числовые, булевы, категориальные, порядковые и их сочетание
- Кластеризация с ограничениями
  - Пользователь может вводить данные об ограничениях
  - Использование знаний о предметной области для определения входных параметров
- Интерпретируемость и удобство использования
- Прочее
  - Обнаружение кластеров произвольной формы
  - Устойчивость к шумам
  - Инкрементальная кластеризация, независимость от порядка ввода
  - Большая размерность данных

# Базовые подходы: разделительная vs. иерархическая кластеризация

- Разделение объектов на непересекающиеся подмножества, каждый объект строго в одном подмножестве



- Иерархическое дерево пересекающихся подмножеств объектов



# Разделительный алгоритм $k$ -means ( $k$ -средних)


- Количество кластеров  $k$  – параметр алгоритма
- Кластер ассоциируется с его *центроидом* (центральной точкой)
- Объект принадлежит кластеру с ближайшим к нему центроидом









Гуго Штейнгауз  
(Hugo Steinhaus)  
(1887-1972)

- 
- 1: Select  $K$  points as the initial centroids.
  - 2: **repeat**
  - 3:   Form  $K$  clusters by assigning all points to the closest centroid.
  - 4:   Recompute the centroid of each cluster.
  - 5: **until** The centroids don't change

# Пример работы $k$ -means



# Пример работы $k$ -means



## Детали алгоритма *k*-means

- Начальные центроиды берутся случайным образом. Результат кластеризации недетерминирован
- Центроид – обычно точка с усредненными координатами точек кластера
- Алгоритм сходится в начальных итерациях для общепринятых метрик
  - часто изменяется условие останова: у малого числа точек изменен кластер
  - может давать локальный минимум вместо глобального

# За и против *k*-means

- Достоинства
  - Невысокая сложность:  $O(n \cdot k \cdot d \cdot i)$ , где  $n$  – мощность множества объектов,  $d$  – размерность объекта,  $i$  – число итераций (обычно  $i \ll n$ )
  - Сходится в начальных итерациях для общепринятых метрик
- Недостатки
  - Необходимость в задании параметра  $k$
  - Недетерминированный результат
  - Может приводить к пустым кластерам в процессе работы
  - Неприменимость к категориальным данным (для них нужно использовать *k*-modes)
  - Неприменимость для кластеров невыпуклой формы
  - Чувствительность к размеру, плотности, шумам и выбросам в данных


# Мера для выявления кластеров в $k$ -means

- Сумма квадратов ошибок, Sum of Squared Errors


$$SSE = \sum_{i=1}^k \sum_{x \in C_i} dist^2(m_i, x)$$

- $C_i$  ( $1 < i \leq k$ ) – кластер
  - $x$  – точка кластера
  - $m_i$  – центроид (mean) кластера
- Из двух вариантов кластеризации выбирается имеющий меньшую суммарную ошибку
    - Увеличение  $k$  уменьшает ошибку. Хороший вариант кластеризации с меньшим  $k$  может иметь меньшее  $SSE$ , чем плохой вариант с большим  $k$


# Различные варианты кластеризации $k$ -means




Оптимальная кластеризация




Суб-оптимальная кластеризация



# Влияние размеров кластеров




**Кластеризуемое  
множество**




**3-means**

# Влияние плотности кластеров




**Кластеризуемое  
множество**




**3-means**

# Влияние формы кластеров




**Кластеризуемое  
множество**




**2-means**

# Увеличение количества кластеров




**Кластеризуемое множество**




**10-means**

- Может помочь, но требует дальнейшего объединения некоторых полученных кластеров (например, с помощью иерархической кластеризации)

# Увеличение количества кластеров




Кластеризуемое множество




10-means

- Может помочь, но требует дальнейшего объединения некоторых полученных кластеров (например, с помощью иерархической кластеризации)

# Увеличение количества кластеров




**Кластеризуемое множество**




**10-means**

- Может помочь, но требует дальнейшего объединения некоторых полученных кластеров (например, с помощью иерархической кластеризации)


# Влияние шумов и выбросов




В данных  
нет шума  
 $S=0.88$



В 3% данных  
есть шум  
 $S=0.62$




В 5% данных  
есть шум  
 $S=0.39$









В 10% данных  
есть шум  
 $S=-0.05$


# Влияние начального выбора центроидов (1)








# Влияние начального выбора центроидов (1)





# Влияние начального выбора центроидов (2)



# Влияние начального выбора центроидов (2)



# Влияние начального выбора центроидов (1 vs. 2)




# Подбор начальных центроидов

- Многократно запустить  $k$ -means, выбрать результат с минимальным значением  $SSE$ 
  - Результат не обязан быть лучшим из возможных
- Выполнить иерархическую кластеризацию случайного подмножества исходных точек для  $k$  кластеров и взять центроиды этих кластеров
  - Работает для небольших подмножеств и значений  $k$
- Взять центроид всех точек, затем  $k - 1$  раз взять точку, наиболее удаленную от всех  $k$  выбранных до этого точек
  - Наиболее удаленная точка может оказаться выбросом
  - Высокая трудоемкость
- Применить предыдущий подход для случайного подмножества точек
- Взять более  $k$  точек, выполнить  $k$ -means, выполнить иерархическую кластеризацию результата

# Алгоритм *k*-means++

- Медленнее, чем случайный выбор начальных центроидов (сложность  $O(\log k)$ ), но лучше по SSE
- Выбор центроидов  
Выбрать случайным образом первый центроид  $C_1$   
**for**  $i := 2$  to  $k$  **do**  
    **for each**  $x_i$   
        найти вес  $x_i$  – квадрат мин расстояния от точки до уже выбранных центроидов  $C_1, \dots, C_j$  ( $1 \leq j < k$ ),  $w_i = \min_{1 \leq j < k} \text{dist}^2(C_j, x_i)$   
    Выбрать случайно новый центроид  $C_i$  с вероятностью  $p_i = \frac{w_i}{\sum_i w_i}$

# Пустые кластеры и стратегии их обработки




- Выбирать точку с наибольшим вкладом в SSE
- Выбирать точку с из кластера с наибольшим SSE
- Если несколько пустых кластеров, повторять

# Техники улучшения *k*-means

- Предобработка
  - Нормализация данных
  - Поиск и удаление выбросов
- Постобработка
  - Удаление маломощных кластеров (выбросы/аномалии)
  - Разбиение «слабых» кластеров с высоким *SSE*
  - Слияние «близких» кластеров с низким *SSE*
- Обработка
  - Применение разбиения и слияния в процессе кластеризации
  - Инкрементное обновление центроидов: не после назначения всех объектов центроиду, а после каждого назначения
    - Каждое назначение обновляет 0-2 центроида
    - Исключаются пустые кластеры



# Бисекционный $k$ -means (иерархическое разбиение)

- 
- 1: Initialize the list of clusters to contain the cluster containing all points.
  - 2: **repeat**
  - 3:   Select a cluster from the list of clusters
  - 4:   **for**  $i = 1$  to *number\_of\_iterations* **do**
  - 5:     Bisect the selected cluster using basic K-means
  - 6:   **end for**
  - 7:   Add the two clusters from the bisection with the lowest SSE to the list of clusters.
  - 8: **until** Until the list of clusters contains  $K$  clusters
- 



# *k*-medoids (PAM, Partitioning Around Medoids)

- Медоид – репрезентативный объект кластера



- Менее чувствителен к шумам и выбросам, чем *k*-means (медоид – объект кластера, центроид – искусственный объект)

# *k*-medoids (PAM, Partitioning Around Medoids)

взять  $k$  случайных объектов в качестве медоидов  $\check{o}_1, \dots, \check{o}_k$

**repeat**

назначить объектам кластер с ближайшим медоидом;

выбрать случайный объект не-медоид  $o$ ;

вычислить цену обмена  $o$  и  $\check{o}$  как разность их  $SSE$


$$E = \sum_{i=1}^k \sum_{p \in C_i} \text{dist}(p, o)^2 - \sum_{i=1}^k \sum_{p \in C_i} \text{dist}(p, \check{o})^2;$$

**if**  $E < 0$  **then**

обменять местами объект  $o$  и медоид  $\check{o}$

**until** нет изменений


# Пример работы $k$ -medoids




$k=2$




Выбрать  $k$  случайных объектов в качестве медоидов




Присвоить оставшимся объектам кластеры по ближайшему медоиду



Выбрать случайный объект не-медоид,  $O_{random}$



Вычислить стоимость обмена медоида и  $O_{random}$



repeat

Если качество улучшилось, поменять медоид и  $O_{random}$

until нет изменений

# Литература

- Han J., Kamber M., Pei J. Data Mining: Concepts and Techniques. 3rd Edition. Morgan Kaufmann, 2011. 740 p. ISBN 978-0123814791
  - 10. Cluster Analysis: Basic Concepts and Methods; 10.1 Cluster Analysis; 10.2 Partitioning Methods, pp. 443-457
- Tan P.-N., Steinbach M., Karpatne A., Kumar V. Introduction to Data Mining. 2nd Edition. Pearson, 2019. 839 p. ISBN: 978-0-13-312890-1
  - 7. Cluster Analysis: Basic Concepts and Algorithms; 7.1 Overview; 7.2 K-means, pp. 525-553