

Практическая работа №6: Кластерный анализ. Метод k-средних

Цель работы

Освоение основных понятий и некоторых методов кластерного анализа, в частности, метода k-средних.

Постановка задачи

Дано конечное множество из объектов, представленных двумя признаками (в качестве этого множества принимаем исходную двумерную выборку, сформированную ранее в практической работе №4). Выполнить разбиение исходного множества объектов на конечное число подмножеств (кластеров) с использованием метода k-means. Полученные результаты содержательно проинтерпретировать.

Порядок выполнения работы

1. Нормализовать множество точек из предыдущего раздела, отобразить полученное множество.
2. Определить «грубую» верхнюю оценку количества кластеров: $\tilde{k} = \lfloor \sqrt{N/2} \rfloor$, где N – число точек.
3. Реализовать алгоритм k-means в двух вариантах:
 1. пересчет центра кластера осуществляется после каждого изменения его состава;
 2. пересчет центра кластера осуществляется лишь после того, как будет завершен просмотр всех данных (шаг процедуры).
4. На каждом шаге процедуры разбиения методом k-means вычислять функционалы качества полученного разбиения:
 1. F_1 – сумма по всем кластерам квадратов расстояний элементов кластеров до центров соответствующих кластеров;
 2. F_2 – сумма по всем кластерам внутрикластерных расстояний между элементами кластеров;
 3. F_3 – сумма по всем кластерам внутрикластерных дисперсий (относительно центров кластеров).
5. Отобразить полученные кластеры, выделить каждый кластер разным цветом, отметить центроиды.
6. Содержательно проинтерпретировать полученные результаты.
7. *Дополнительные необязательные задания:*
 1. Реализовать алгоритмы *k-medians* и *k-medoids*. Отобразить полученные кластеры, выделить каждый кластер разным цветом, отметить центроиды. Провести оценку методов, сделать выводы.
 2. С помощью *метода локтя* и *метода силуэтов* выявить для каждого метода оптимальное количество кластеров.

3. Реализовать модификацию *k-means++*. Объяснить её преимущества. Сравнить с обычным методом *k-means*.

Содержание отчёта

1. Цель работы.
2. Краткое изложение основных теоретических понятий.
3. Постановка задачи с кратким описанием порядка выполнения работы.
4. Необходимые формулы, рисунки и таблицы.
5. Краткие выводы по полученным результатам.
6. Общий вывод по проделанной работе.
7. Код программы (если имеется).

Вопросы для самоконтроля

1. Сформулировать основные задачи кластерного анализа.
2. Дать классификацию и охарактеризовать основные методы кластерного анализа.
3. Критерии качества кластерных разбиений.
4. Описать и прокомментировать метод *k-means* кластерного анализа.

From:
<https://se.moevm.info/> - МОЭВМ Вики [se.moevm.info]

Permanent link:
https://se.moevm.info/doku.php/courses:statistical_methods_of_experimental_data_handling:prac6

Last update:

