

Алгоритмы кластеризации

Сергей Николенко

Машинное обучение — ИТМО, осень 2006

Outline

- 1 Введение
 - Суть
 - Виды кластеризации
 - Как оценивать кластеризацию
- 2 Иерархическая кластеризация
 - Идея алгомеративной кластеризации
 - Алгоритм
 - Single-link vs. complete-link
- 3 Кластеризация методами теории графов
 - Очевидный алгоритм
 - Минимальное остовное дерево
- 4 Другие методы
 - Quality Threshold clustering
 - Алгоритм FOREL

Суть лекции

- *Кластеризация* — типичная задача статистического анализа: задача классификации объектов одной природы в несколько групп так, чтобы объекты в одной группе обладали одним и тем же свойством.
- Под свойством обычно понимается близость друг к другу относительно выбранной метрики.

Чуть более формально

- Есть набор тестовых примеров $X = \{x_1, \dots, x_n\}$ и функция расстояния между примерами ρ .
- Требуется разбить X на непересекающиеся подмножества (кластеры) так, чтобы каждое подмножество состояло из похожих объектов, а объекты разных подмножеств существенно различались.

Зачем это нужно

- Data mining в самом широком смысле; например, разделить веб-документы на жанры и т.п.
- Распознавание образов.
- Анализ социальных сетей.
- ...

Виды кластеризации

- Иерархические: последовательно строим кластеры из уже найденных кластеров.
 - Агломеративная (объединительная) — начинаем с индивидуальных элементов, затем объединяем.
 - Разделительная — начинаем с одного кластера, потом делим.
- Неиерархические: оптимизируем некую целевую функцию.
 - Алгоритмы теории графов.
 - Алгоритм EM.
 - Алгоритм k -средних (k -means).
 - Нечеткие алгоритмы.

Оценка кластеризации

- Действительно, пусть есть несколько разбиений на кластеры. Как их сравнить?
- Пусть нам нужно кластеризовать точки в d -мерном пространстве.

Оценка кластеризации

- Действительно, пусть есть несколько разбиений на кластеры. Как их сравнить?
- Пусть нам нужно кластеризовать точки в d -мерном пространстве.
- Логично минимизировать среднее внутрикластерное расстояние:

$$\frac{\sum_{i < j, c(x_i) = c(x_j)} \rho(x_i, x_j)}{\sum_{i < j, c(x_i) = c(x_j)} 1} \longrightarrow \min .$$

- И максимизировать среднее межкластерное расстояние:

$$\frac{\sum_{i < j, c(x_i) \neq c(x_j)} \rho(x_i, x_j)}{\sum_{i < j, c(x_i) \neq c(x_j)} 1} \longrightarrow \max .$$

Оценка кластеризации

- Действительно, пусть есть несколько разбиений на кластеры. Как их сравнить?
- Пусть нам нужно кластеризовать точки в d -мерном пространстве.
- Если алгоритм вычисляет центры кластеров μ_c , то можно более эффективно:

$$\sum_{c \in C} \frac{1}{|c|} \sum_{x \in c} \rho^2(x, \mu_c) \longrightarrow \min,$$
$$\sum_{c \in C} \rho^2(\mu_c, \mu) \longrightarrow \max,$$

где μ — общий центр масс всей выборки.

- Чтобы учесть и стремление к минимуму, и стремление к максимуму, устремляют к минимуму отношение двух

Outline

- 1 Введение
 - Суть
 - Виды кластеризации
 - Как оценивать кластеризацию
- 2 Иерархическая кластеризация
 - Идея алгомеративной кластеризации
 - Алгоритм
 - Single-link vs. complete-link
- 3 Кластеризация методами теории графов
 - Очевидный алгоритм
 - Минимальное остовное дерево
- 4 Другие методы
 - Quality Threshold clustering
 - Алгоритм FOREL

Идея

- Есть точки $x_1, x_2, \dots, x_n$ в пространстве. Нужно кластеризовать.
- Считаем каждую точку кластером. Затем ближайшие точки объединяем, далее считаем единым кластером. Затем повторяем.
- Получается дерево.

Алгоритм

$\text{HierarchyCluster}(X = \{x_1, \dots, x_n\})$

- Инициализируем $C = X$, $G = X$.
- Пока в C больше одного элемента:
 - Выбираем два элемента C c_1 и c_2 , расстояние между которыми минимально.
 - Добавляем в G вершину c_{12} , соединяем ее с вершинами c_1 и c_2 .
 - $C := C \cup \{c_{12}\} \setminus \{c_1, c_2\}$.
- Выдаем G .

Результат

- В итоге получается дерево кластеров, из которого потом можно выбрать кластеризацию с требуемой степенью детализации (обрезать на том или ином максимальном расстоянии).
- Все ли понятно?

Результат

- В итоге получается дерево кластеров, из которого потом можно выбрать кластеризацию с требуемой степенью детализации (обрезать на том или ином максимальном расстоянии).
- Все ли понятно?
- Остается вопрос: как подсчитывать расстояние между кластерами?

Single-link vs. complete-link

- *Single-link* алгоритмы считают *минимум* из возможных расстояний между парами объектов, находящихся в кластере.
- *Complete-link* алгоритмы считают *максимум* из этих расстояний.
- Какие особенности будут у single-link и complete-link алгоритмов? Чем они будут отличаться?

Упражнение

Упражнение

Реализовать single-link и complete-link алгоритмы
агломеративной кластеризации для точек из евклидова
пространства размерности n .

Outline

- 1 Введение
 - Суть
 - Виды кластеризации
 - Как оценивать кластеризацию
- 2 Иерархическая кластеризация
 - Идея алгомеративной кластеризации
 - Алгоритм
 - Single-link vs. complete-link
- 3 Кластеризация методами теории графов
 - Очевидный алгоритм
 - Минимальное остовное дерево
- 4 Другие методы
 - Quality Threshold clustering
 - Алгоритм FOREL

Очевидный алгоритм

- Нарисуем полный граф с весами, равными расстоянию между объектами.
- Выберем лимит расстояния r и выбросим все ребра длиннее r .
- Компоненты связности полученного графа — это наши кластеры.

Минимальное остовное дерево

- Минимальное остовное дерево — дерево, содержащее все вершины (связного) графа и имеющее минимальный суммарный вес своих ребер.
- Алгоритм Краскала (Kruskal): выбираем на каждом шаге ребро с минимальным весом, если оно соединяет два дерева, добавляем, если нет, пропускаем.

Алгоритм Борувки (Boruvka)

- Начинаем с графа G и пустого множества ребер T .
- Пока $G|_T$ не связный:
 - Инициализируем множество ребер $E := \emptyset$.
 - Для каждой компоненты связности:
 - Инициализируем множество ребер $S := \emptyset$.
 - Для каждой вершины компоненты добавляем в S самое дешевое ребро, соединяющее вершину с какой-либо вершиной другой компоненты.
 - Добавляем самое дешевое ребро из S в E .
 - $T := T \cup E$.
- Он работает быстрее алгоритма Краскала (за время $O(E \log V)$).
- Впрочем, самый быстрый из известных алгоритмов MST работает за время $O(E \alpha(V))$, где α — обратная к функции Аккермана.

Кластеризация

- Как использовать минимальное остовное дерево для кластеризации?

Кластеризация

- Как использовать минимальное остовное дерево для кластеризации?
- Построить минимальное остовное дерево, а потом выкидывать из него ребра максимального веса.
- Сколько ребер выбросим, столько кластеров получим.

Упражнение

Упражнение

Реализовать алгоритм кластеризации методом минимального остовного дерева.

Outline

- 1 Введение
 - Суть
 - Виды кластеризации
 - Как оценивать кластеризацию
- 2 Иерархическая кластеризация
 - Идея алгомеративной кластеризации
 - Алгоритм
 - Single-link vs. complete-link
- 3 Кластеризация методами теории графов
 - Очевидный алгоритм
 - Минимальное остовное дерево
- 4 Другие методы
 - Quality Threshold clustering
 - Алгоритм FOREL

Идея алгоритма

- Был придуман для кластеризации генов.
- Однако, вопреки ожиданиям, не слишком эффективен; для генома нечего и думать его запускать.

Алгоритм

- Зафиксируем quality threshold — предельное расстояние между объектами кластера.
- Выбрать случайный ген и начать наращивать кластер, пока это возможно (не превышая предельного расстояния).
- Повторить для других случайных генов, пока все гены не будут покрыты (пересечения кластеров возможны).
- Выбрать кластер максимального размера и удалить его из множества тестовых объектов.
- Запускать то же самое рекурсивно до тех пор, пока размер максимального кластера не станет слишком большим.

Плюсы и минусы

- Достоинства:
 - Гарантированное качество: все кластеры соответствуют заранее заданным критериям.
 - Число кластеров задавать не нужно.
 - Рассматриваются все возможные кластеры: exhaustive search.
- Недостатки:
 - Относительно медленно работает.
 - Нужно задавать threshold; если он окажется плохо подобран, алгоритм будет работать *очень* медленно.

Упражнение

Упражнение

Реализовать алгоритм кластеризации QT.

История

- FOREL означает «формальный элемент». Единственный из популярных алгоритмов кластеризации, изобретенный в СССР.
- Предложен Загоруйко и Елкиной в 1967 году для решения одной палеонтологической задачи.

Идея

- Предположим, что мы находимся в линейном пространстве ($\mathbb{R}^n$ подходит).
- Пусть задана точка x_0 и параметр R .
- Выделим все точки из тестового набора, попадающие в сферу радиуса R с центром в x_0 .
- Перенесем центр кластера из x_0 в точку центра масс точек, которые были выбраны на предыдущем шаге.
- Повторять, пока центр не останется на месте.
- Центр — это и есть «формальный параметр», т.к. он не обязательно содержится в исходной выборке.

Алгоритм

FOREL(X):

- Инициализировать множество некластеризованных точек $U := X$ и множество кластеров $C := \emptyset$.
- Пока $U \neq \emptyset$:
 - Выбрать случайную точку x_0 .
 - Пока процесс не стабилизируется:
 - Образовать кластер $c = \{x \in X | \rho(x, x_0) < R\}$.
 - $x_0 := \frac{1}{|c|} \sum_{x \in c} x$.
 - $U := U \setminus c$, $C := C \cup \{c\}$.
- Выдать множество полученных кластеров C .

Упражнение

Упражнение

Реализовать алгоритм кластеризации FOREL.

Спасибо за внимание!

- Lecture notes, слайды и коды программ появятся на моей homepage:
`http://logic.pdmi.ras.ru/~sergey/index.php?page=teaching`
- Присылайте любые замечания, коды программ на других языках, решения упражнений, новые численные примеры и прочее по адресам:
`sergey@logic.pdmi.ras.ru, smartnik@inbox.ru`