

1 Кластерный анализ

1.1 Описании данных

Пусть из некоторого множества π (*генеральной совокупности*) отобрано n объектов $I = (I_1, \dots, I_n)$. У каждого из этих объектов измеряется несколько характеристик $C = (C_1, \dots, C_p)^T$. Мы предполагаем, что эти характеристики являются (*количественными*). Пусть далее x_{ij} есть результат измерения i -й характеристики у объекта I_j . Тогда $X_j = (x_{1j}, \dots, x_{pj})^T$ есть измерения всех его характеристик у объекта I_j . В итоге мы имеем матрицу измерений:

$$X = (X_1, \dots, X_n) .$$

Далее каждый набор X_j рассматривается как вектор в R^p .

1.2 Задача кластерного анализа

Пусть $m < n$. Требуется на основе измерений X разбить множество объектов I на m классов (*кластеров*) $\pi_1, \dots, \pi_m$ так, чтобы:

- 1) каждый объект I_j принадлежал одному и только одному классу;
- 2) объекты внутри одного класса были бы в некотором смысле *сходными*;
- 3) объекты из разных классов были бы *несходными*.

Для решения этой задачи используется некоторая *целевая функция*. Она учитывает как число классов, так и качество группировки. Интуитивно ясно, объекты I_j и I_k нужно объединять в один класс, если расстояние между X_j и X_k будет *достаточно малым*, а для точек из разных классов оно должно быть *достаточно большим*.

1.3 Меры сходства

В этом разделе мы покажем как измерить близость выбранных объектов. Пусть в R^p задано некоторое расстояние (метрика) d . Рассмотрим несколько типичных примеров.

- 1) *Евклидово расстояние*.

$$d_2(X_k, X_j) := n \left[\sum_{i=1}^p (x_{ik} - x_{ij})^2 \right]^{1/2} .$$

- 2) *l_1 -норма*.

$$d_1(X_k, X_j) := n \left[\sum_{i=1}^p |x_{ik} - x_{ij}| \right] .$$

3) *Максимальная норма.*

$$d_{\infty}(X_k, X_j) := \sup_i |x_{ik} - x_{ij}| .$$

4) *Расстояние Махаланобиса.*

$$D^2(X_k, X_j) := (X_k - X_j)^T W^{-1} (X_k - X_j) ,$$

где W есть так называемая матрица рассеяния, построенная по измерениям X (смотри ниже).

Важной особенностью этого расстояния является то, что оно не меняется при линейных преобразованиях: пусть $Y = B \cdot X$, тогда:

$$D^2(Y_k, Y_j) = D^2(X_k, X_j) .$$

Всюду далее через D будем обозначать матрицу попарных расстояний d_{kj} между векторами X_k X_j .

Определение 1 . Неотрицательная функция $s(X_k, X_j) =: s_{kj}$ называется **мерой сходства**, если:

- 1) $0 \leq s(X_k, X_j) < 1$, если $X_k \neq X_j$;
- 2) $s(X_k, X_k) = 1$;
- 3) $s(X_k, X_j) = s(X_j, X_k)$.

Обозначим $S = (s_{kj})$.

Замечание 1 .

- 1) Величина s_{kj} называется **мерой сходства** измерений X_k и X_j .
- 2) Если X состоит из нулей и единиц, то s_{kj} называется **коэффициентом ассоциации** или **парным коэффициентом сопряженности**.
- 3) В статистике в качестве s_{kj} используют выборочные коэффициенты корреляции r_{kj} .

Рассмотрим теперь меры рассеяния и разнородности множества объектов $I = (I_1, \dots, I_n)$.

Определение 2 . Пусть X есть матрица измерений. Величина

$$S_d := \frac{1}{2} \sum_{k,j=1}^n d(X_k, X_j)$$

называется **общим** рассеянием множества объектов I , соответствующим данному расстоянию d .

Определение 3 . Величина $\bar{s}_d := s_d/N_d$, где $N_d = (n^2 - n)/2$, называется **средним рассеянием** множества объектов I .

В статистике часто используют следующие понятия.

Определение 4 . $p \times p$ -матрица

$$S_X := \sum_{j=1}^n (X_j - \bar{X})(X_j - \bar{X})^T \quad (1)$$

называется **матрицей рассеяния** множества X , где

$$\bar{X} = \frac{1}{n} \sum_{j=1}^n X_j .$$

Определение 5 . След матрицы S_X называется **статистическим рассеянием** множества X и обозначается

$$\begin{aligned} s_t := \text{tr} S_X &= \sum_{j=1}^n \sum_{i=1}^p (X_{ij} - \bar{X}_i)^2 = \sum_{j=1}^n (X_j - \bar{X})^T (X_j - \bar{X}) = \\ &= \frac{1}{n} \sum_{j < k} d^2(X_j, X_k) . \end{aligned}$$

Определение 6 . Определитель $|S_X|$ матрицы S_X называется **статистическим рассеиванием**, соответствующим определителю, и обозначается s_D .

1.4 Расстояние между кластерами

Общая идея кластерного анализа состоит в том, что кластеры строятся последовательно. Начинаем с единичных объектов, рассматриваемых как кластеры. Если мы уже построили некоторую систему кластеров, то далее мы объединяем некоторые кластеры, которые лежат близко друг к другу. Окончательное разбиение получается с помощью некоторой *целевой функции*. Для ее построения используют понятия *внутренней однородности* кластера и меры *разнородности* кластеров между собой.

Пусть мы имеем два набора объектов $I = (I_1, \dots, I_{n_1})$ и $J = (J_1, \dots, J_{n_2})$, которые приводят к двум множествам измерений $X = (X_1, \dots, X_{n_1})$ и $Y = (Y_1, \dots, Y_{n_2})$.

Определение 7 . Величина

$$D_1(I, J) := \min_{k,j} d(X_k, Y_j)$$

называется **минимальным локальным расстоянием** между кластерами I и J .

Определение 8 . Величина

$$D_2(I, J) := \max_{k,j} d(X_k, Y_j)$$

называется **максимальным локальным расстоянием** между кластерами I и J .

Определение 9 . Величина

$$D_3(I, J) := \sum_k \sum_j d(X_k, Y_j) / n_1 \cdot n_2$$

называется **средним расстоянием** между кластерами I и J .

Определение 10 . Величина

$$D_4(I, J) := \frac{n_1 n_2}{n_1 + n_2} (\bar{X} - \bar{Y})^T (\bar{X} - \bar{Y})$$

называется **статистическим расстоянием** между кластерами I и J .

Смысл последнего понятия проясняется ниже. Рассмотрим кластер $K = I \cup J$. По аналогии с (1) определим

$$S_K = \sum_{k=1}^{n_1} (X_k - M)(X_k - M)^T + \sum_{j=1}^{n_2} (Y_j - M)(Y_j - M)^T, \quad (2)$$

где

$$M = (\sum_k X_k + \sum_j Y_j) / (n_1 + n_2) = (n_1 \bar{X} + n_2 \bar{Y}) / (n_1 + n_2). \quad (3)$$

Нетрудно показать, что

$$S_K = S_I + S_J + \frac{n_1 n_2}{n_1 + n_2} (\bar{X} - \bar{Y})(\bar{X} - \bar{Y})^T. \quad (4)$$

Определение 11 . Матрица

$$\frac{n_1 n_2}{n_1 + n_2} (\bar{X} - \bar{Y})(\bar{X} - \bar{Y})^T \quad (5)$$

называется **матрицей межгруппового рассеивания**.

Определение 12 . Величину

$$tr \frac{n_1 n_2}{n_1 + n_2} (\bar{X} - \bar{Y})(\bar{X} - \bar{Y})^T = \frac{n_1 n_2}{n_1 + n_2} (\bar{X} - \bar{Y})^T (\bar{X} - \bar{Y}) \quad (6)$$

называют **статистическим расстоянием** между кластерами I и J или **межгрупповой суммой квадратов**

Тогда (3) можно интерпретировать следующим образом: общая сумма квадратов складывается из внутригрупповой суммы квадратов и межгрупповой суммы квадратов.

1.5 Последовательное построение кластеров

Обычно кластеры строят последовательно. Общая схема такого построения имеет следующий вид:

- 1) Сначала все объекты рассматривают как отдельные кластеры.
- 2) Выбирают два порога s и r .
- 3) Если все кластеры находятся на расстоянии более, чем s , то все заканчивается.
- 4) Если есть кластеры, которые ближе друг к другу, чем s , то находим два наиболее близких и объединяем их.
- 5) Находим расстояния внутри кластеров и расстояния между кластерами.
- 6) Процедура продолжается до тех пор, пока расстояния внутри всех кластеров не более r , а между кластерами не более s .

Существуют различные методы реализации этой схемы. Они программно реализованы в ППП по статистике. Подробное описание можно найти в руководствах по кластерному анализу.

Процедура может привести и к построению только одного кластера, т.е. ничего разделить не удалось.

Оценка качества работы процедура - это отдельная важная задача.

Список литературы

- [1] Мандель И.Д. Кластерный анализ.
- [2] Дюран Б., Оделл П. Кластерный анализ
- [3] Факторный, дискриминантный и кластерный анализ (сборник статей).