

Математические основы информационной безопасности

Груздев Дмитрий Николаевич

Обучение без учителя

Кластеризация

x_1, x_2, \dots, x_m – обучающая выборка

$\rho(x_i, x_j)$ – расстояние между объектами

Построить:

- Y – множество кластеров
- $A: X \rightarrow Y$ – алгоритм кластеризации объектов

Требования к кластерам:

- кластер состоит из близких объектов
- объекты разных кластеров существенно различны

Кластеризация




Трудности при формализации задачи

- существует много критериев качества кластеризации
- число кластеров обычно неизвестно заранее


Цели кластеризации:

- упростить обработку данных
- сократить объем хранимых данных
- выделить нетипичные признаки
- построить иерархию множества объектов


Виды кластеров



Иерархическая кластеризация




Последовательно объединяем два ближайших друг к другу кластера в новый.



Расстояние между кластерами

расстояние между центрами

$$\rho(W, S) = \frac{|S||W|}{|S|+|W|} \rho^2 \left(\sum_{w \in W} \frac{w}{|W|}, \sum_{s \in S} \frac{s}{|S|} \right) - \text{расстояние Уорда}$$




Индукционное вычисление расстояния Уорда:

$$W = A \cup B$$

$$\rho(A \cup B, S) = \alpha * \rho(A, S) + \beta * \rho(B, S) + \gamma * \rho(A, B), \text{ где}$$


$$\alpha = (|A|+|S|)/(|S|+|W|), \beta = (|B|+|S|)/(|S|+|W|), \gamma = -|S|/(|S|+|W|)$$

Объекты




Объекты

Hierarchical Clustering Dendrogram



Объекты



Метод k-средних


x_1, x_2, \dots, x_m – обучающая выборка

$$x_i = (x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(n)})$$


Алгоритм:

1. Задать количество кластеров и их центры $x_{k1}, \dots x_{km}$.
2. Отнести каждый объект к ближайшему центру.
3. Перенести координаты центров кластеров в центры тяжести соответствующих групп объектов.
4. Повторять 2 и 3, пока происходят переходы объектов между кластерами.

Метод k-средних



Оптимальное число кластеров




Ошибка кластеризации:



$$E_m = \sum_{1 \leq i \leq m} \sum_{1 \leq j \leq |K_i|} \|x_{K_i(j)} - x_{K_i(i)}\|^2$$

Выбор m – числа кластеров:

$$E_m - E_{m+1} \ggg E_{m-1} - E_m$$



Метод главных компонент



Метод главных компонент

x_1, x_2, \dots, x_m – обучающая выборка

$$x_i = (x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(n)})$$

$$x_i = (g_i^{(1)}, g_i^{(2)}, \dots, g_i^{(k)}), \quad k \leq n$$

$$x_i^{(j)} \approx \sum g_i^{(l)} u_l = h_i^{(j)}$$

$$\sum_{1 \leq i \leq m} \sum_{1 \leq j \leq n} (h_i^{(j)} - x_i^{(j)})^2 \rightarrow \min_{(u, g)}$$

Преобразование признаков

$$X = \begin{pmatrix} x_1^{(1)} & \dots & x_1^{(n)} \\ \vdots & & \vdots \\ x_m^{(1)} & \dots & x_m^{(n)} \end{pmatrix} \quad G = \begin{pmatrix} g_1^{(1)} & \dots & g_1^{(k)} \\ \vdots & & \vdots \\ g_m^{(1)} & \dots & g_m^{(k)} \end{pmatrix} \quad U = \begin{pmatrix} u_1^{(1)} & \dots & u_1^{(k)} \\ \vdots & & \vdots \\ u_n^{(1)} & \dots & u_n^{(k)} \end{pmatrix}$$


$$X \approx GU^T; \quad \|GU^T - X\|^2 \rightarrow \min_{G,U}$$

Решение:

$$G = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_k), \quad \lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_k \geq \dots \geq \lambda_n$$

- $UU^T = I_k$ – ортонормирована, и $G \approx XU$, $X \approx GU^T$
- $$\|GU^T - X\|^2 = \lambda_{k+1} + \lambda_{k+2} + \dots + \lambda_n$$

Эффективная размерность



$$E_k = \|GU^\top - F\|^2 / \|F\|^2 = (\lambda_{k+1} + \dots + \lambda_n) / (\lambda_1 + \dots + \lambda_n)$$

Установить допустимую погрешность $E_k \leq \varepsilon$ или

если $E_{k-1} \gg E_k$, то стоит выбрать размерность k .

Диагностика аномалий

x_1, x_2, \dots, x_m – обучающая выборка

$x_i = (x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(n)})$

Особенности:

- большое количество нормальных результатов,
- малое число (отсутствие) результатов с аномалиями,
- типы аномалий трудно систематизировать,
- возможны неизвестные аномалии.

Случайные величины

Теория вероятности

X, Y – случайные величины

M_x – математическое ожидание X

D_x – дисперсия X

$\sigma_x = D_x^{1/2}$ – стандартное отклонение X

$\text{cov}_{XY} = M((X - M_x)(Y - M_y))$ – ковариация
 X и Y

$$r_{XY} = \frac{\text{cov}_{XY}}{\sigma_x \sigma_y} -$$

коэффициент линейной корреляции
(коэффициент корреляции Пирсона)

Математическая статистика

$X = \{x_1, \dots, x_N\}, Y = \{y_1, \dots, y_N\}$ – выборки

$\bar{X} = \frac{1}{n} \sum x_i$ - выборочное среднее

$S_x^2 = \frac{1}{n} \sum (x_i - \bar{X})^2$ - выборочная дисперсия

$\text{cov}_{XY} = \frac{1}{n} \sum (x_i - \bar{X})(y_i - \bar{Y})$ - выборочная
ковариация

$$r_{XY} = \frac{\text{cov}_{XY}}{S_x S_y} = \frac{\sum (x_i - \bar{X})(y_i - \bar{Y})}{\sqrt{\sum (x_i - \bar{X})^2 \sum (y_i - \bar{Y})^2}}$$

коэффициент корреляции Пирсона

Вероятность появления объекта

$$x(i) \sim N(\mu_i, \sigma_i^2)$$

$$\mu_i = \sum_{1 \leq j \leq m} x_j(i) / m \text{ -- выборочное среднее}$$

$$\sigma_i^2 = \sum_{1 \leq j \leq m} (x_j(i) - \mu_i)^2 / m \text{ -- выборочная дисперсия}$$

$$p(x^{*(i)}) = p(x^{*(i)}; \mu_i, \sigma_i^2) = f(x^{*(i)}; \mu_i, \sigma_i^2) = \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left[-\frac{(x^{*(i)} - \mu_i)^2}{2\sigma_i^2}\right]$$

$$x^* = (x^{*(1)}, \dots, x^{*(n)})$$

Если $x^{(1)}, x^{(2)}, \dots, x^{(n)}$ – независимы, то

$$p(x^*) = p(x^{*(1)}; \mu_1, \sigma_1^2) * p(x^{*(2)}; \mu_2, \sigma_2^2) * \dots * p(x^{*(n)}; \mu_n, \sigma_n^2)$$

Диагностика аномалий

Алгоритм диагностики:

- выбрать $\varepsilon > 0$ пороговое:
- если $p(x^*) < \varepsilon$, то объект относится к аномальным.

Настройка ε :

- алгоритм должен определять известные аномалии,
- алгоритм не должен относить к аномалиям нормальные объекты
- если не удается подобрать пороговый параметр, то нужны другие признаки объектов

scikit-learn

<https://sesc-infosec.github.io/>