


K-means


K=3



$$\sum_{j=1}^K W(c_j)$$

Hierarchical clustering (Grupowanie hierarchiczne)

$$x_1, x_2, \dots, x_n \in \mathbb{R}^p$$



1) Zaczynamy od n grup $\{x_1\}, \{x_2\}, \dots, \{x_n\}$

• ustalamy pewną miarę (nie)podobieństwa między obserwacjami, np. odległość euklidesową

2) Dla $i = n, n-1, \dots, 2$:

a) obliczamy podobieństwa pomiędzy każdą parą ^{spójną} grup

b) łączymy ze sobą dwie najbardziej podobne grupy, otrzymując $i-1$ grup

Do a) potrzebujemy ustalić, jak liczymy podobieństwo między grupami. Np.

$$\cdot d(K_1, K_2) = \max_{\substack{x \in K_1 \\ y \in K_2}} d(x, y)$$

kompletne

$$K_1, K_2 \subset \{x_1, \dots, x_n\}$$


$$\cdot d(K_1, K_2) = \frac{1}{|K_1| |K_2|} \sum_{\substack{x \in K_1 \\ y \in K_2}} d(x, y)$$

$$\cdot d(K_1, K_2) = \min_{\substack{x \in K_1 \\ y \in K_2}} d(x, y)$$

pojedyncze (single)

'linkage' (metoda połączenia)

średnie



PCA (principal component analysis)

metoda zmniejszenia wymiarów

$$X = \begin{bmatrix} x_{11} & \dots & x_{1p} \\ \vdots & & \vdots \\ x_{n1} & \dots & x_{np} \end{bmatrix} \begin{bmatrix} \phi_{11} \\ \vdots \\ \phi_{p1} \end{bmatrix}$$

$x_1, x_2, \dots, x_n \in \mathbb{R}^p$
 \parallel
 (x_{11}, \dots, x_{1p})

pierwsze współrzędne: znajdujemy $(\phi_{11}, \phi_{21}, \dots, \phi_{p1}) \in \mathbb{R}^p$, aby

$$z_{1j} = x_{j1} \phi_{11} + x_{j2} \phi_{21} + \dots + x_{jp} \phi_{p1}, \quad j=1, \dots, n$$



wiaty możliwie ~~duży~~ ^{maximalny} ~~wariancji~~, przy założeniu $\|(\phi_{11}, \dots, \phi_{p1})\|_2 = 1$.

Przy założeniu, że $\sum_{j=1}^n x_{jk} = 0$ (średnia zero) dla $k=1, \dots, p$;

$$\sum_{j=1}^n \left(\sum_{i=1}^p x_{ji} \phi_{i1} \right)^2 = \sum_{j=1}^n \langle X_j \cdot \phi_1, X_j \cdot \phi_1 \rangle =$$

$$= \langle X \cdot \phi_1, X \cdot \phi_1 \rangle \quad X \cdot \phi_1 = \left(\sum_{i=1}^p x_{ji} \phi_{i1} \right)_{j=1}^n$$

$$= \sum_{j=1}^n \left(\sum_{i=1}^p x_{ji} \phi_{i1} \right)^2$$



max: $\langle X\phi_1, \phi_1 \rangle = \langle \underbrace{X^T X}_{\text{(symetryczne) nieujemnie określone}} \phi_1, \phi_1 \rangle$

$$(AB)^T = B^T A^T$$

ϕ_1 — wektor własny $X^T X$ odpowiadający największej wartości własnej

$$(X^T X)^T = X^T X^{TT} = X^T X$$

$$\langle X^T X y, y \rangle = \langle x_y, x_y \rangle \geq 0$$

druga współwzajemność: szukamy $\phi \in \mathbb{R}^p$, $\|\phi\|_2 = 1$, $\langle \phi, \phi_1 \rangle = 0$ t.j. wektory



ϕ_2

$$\langle X^T X \phi, \phi \rangle \text{ — niesymetryczne}$$

ϕ_2 — wektor własny $X^T X$ odp. drugiej największej wartości własnej

itd.

Dostajemy więc układ współwzajemnych $(\phi_1, \phi_2, \dots, \phi_p)$



Poszci ϕ_1, \dots, ϕ_p mowno weliy od porozklowy normalizuj:

(porozklowa jedynka ~~120~~)

$$x_1 \approx 10^5$$

$$x_2 \approx 10^2$$

$$x_3 \approx 1$$