

BAB II

ANALISA CLUSTER

Dalam analisa clustering, setiap elemen di dalam himpunan N disajikan dalam vektor, dengan elemen-elemen berupa karakteristik untuk atribut yang digunakan sebagai informasi awal untuk pengelompokan (Grouping). Diasumsikan bahwa $x_i = (x_{1i}, x_{2i}, \dots, x_{zi}) \in R^z$; $i \in N$. Didefinisikan jarak antara dua elemen dari N , seperti pada definisi berikut :

2.1. Mencari Jarak Antara Dua Elemen

Definisi :

Suatu fungsi riil d_{ij} , i dan $j \in N$ adalah metrik atau ukuran jarak, jika d_{ij} memenuhi kondisi berikut :

1. $d_{ij} \geq 0$, $d_{ij} = 0$ jika $i = j$
2. $d_{ij} = d_{ji}$
3. $d_{ik} + d_{kj} \geq d_{ij}$; $i, j, k \in N$

Dengan menganggap beberapa jarak yang digunakan, d_{ij} dinyatakan dalam bentuk :

1. $d_{ij} = \left[\sum_{k=1}^z |X_{ik} - X_{jk}|^r \right]^{1/r}$; r integer positif dalam fungsi i dan j disebut metrik minkowski. Jika $r = 1$ disebut matriks absolut, jika $r = 2$ disebut metrik euclid.

$$2. d_{ij} = \left[\sum_{k=1}^z W_k |X_{ik} - X_{jk}|^r \right]^{1/r}, r \text{ integer positif disebut jarak terboboti}$$

minkowski (*weighted Minkowski distance*). Jika $r = 1,2$ didapat hubungan antara berat absolut dan metrik euclid.

3. $d_{ij} = (X_i - X_j)' P (X_i - X_j)$ dimana P adalah matriks simetrik semi definite positif $z \times z$ disebut metrik euclid umum (*general Euclidean metric*) dan diberikan berat suatu pasangan karakteristik $d_{ij} = (X_i - X_j)' \Sigma_z^{-1} (X_i - X_j)$ dimana Σ_z adalah matriks varian-covarian yang menghubungkan karakteristik z .

Metrik ini lebih umum dari metrik euclid berat pada $\Sigma_z = I_z$. Jarak ini disebut Mahalanobis D^2 . Dengan d_{ij} adalah jarak antara i dan j untuk $i, j \in N$. Metrik dari d_{ij} disebut matriks disimilaritas.

Contoh aplikasi matriks Mahalanobis :

Jika diberikan n obyek dan p variabel, maka diberikan jajaran matriks $x = (x_{i1}, x_{i2}, \dots, x_{in}) \in R^p$ dimana $i \in N$ matriks X diberikan seperti di bawah :

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{bmatrix}_{n \times p}$$

Definisi mean, varian - kovarian dan product momen korelasi

- Mean dari variabel x dan y

$$\bar{x} = \sum_{i=1}^n \frac{x_i}{n} \quad \text{dan} \quad \bar{y} = \sum_{i=1}^n \frac{y_i}{n}$$

dari mean di atas diperoleh

$$\hat{x} = \begin{bmatrix} x_1 - \bar{x} \\ \vdots \\ x_n - \bar{x} \end{bmatrix} \quad \text{dan} \quad \hat{x}^T = [(x_1 - \bar{x}) \cdots (x_n - \bar{x})]$$

$$\hat{y} = \begin{bmatrix} y_1 - \bar{y} \\ \vdots \\ y_n - \bar{y} \end{bmatrix} \quad \text{dan} \quad \hat{y}^T = [(y_1 - \bar{y}) \cdots (y_n - \bar{y})]$$

- varian dan covarian

$$\text{cov}(x, y) = \hat{x}^T \hat{y}$$

$$= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

$$\text{var}(x) = \hat{x}^T \hat{x}$$

$$= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

- product momen korelasi

$$r = (x, y)$$

$$= \frac{\text{cov}(x, y)}{\{\text{var}(x) \text{var}(y)\}}$$

$$= \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\left[\left(\sum_{i=1}^n (x_i - \bar{x})^2 \right) \left(\sum_{i=1}^n (y_i - \bar{y})^2 \right) \right]^{\frac{1}{2}}}$$

product momen korelasi dihitung sebagai ukuran gabungan antara nilai vektor dari dua data unit. Cronbach and Gleser (1953) menunjukkan koefisien korelasi mempunyai karakter limit matriks khususnya jika x_{ij} adalah nilai untuk j data unit pada i variabel, maka didefinisikan mean dan scatter untuk j data unit sebagai

$$\bar{x}_j = \sum_{i=1}^n \frac{x_{ij}}{n} \quad s_j = \left[\sum_{i=1}^n (x_{ij} - \bar{x}_j)^2 \right]^{\frac{1}{2}}$$

dari statistik ini, untuk mentransformasikan nilai dari setiap data unit pada rata-rata nol dan unit scatter diperoleh jarak euclid antara unit data sebagai ukuran

ditransformasikan nilai $\hat{x}_{ij} = \frac{(x_{ij} - \bar{x}_j)}{s_j}$ adalah

$$\begin{aligned} d^2(x_j, x_k) &= \sum_{i=1}^n \left[\frac{x_{ij} - \bar{x}_j}{s_j} - \frac{x_{ik} - \bar{x}_k}{s_k} \right]^2 \\ &= \frac{1}{s_j^2 s_k^2} \left[s_j^2 s_k^2 - 2s_j s_k \sum_{i=1}^n (x_{ij} - \bar{x}_j)(x_{ik} - \bar{x}_k) + s_j^2 s_k^2 \right] \\ &= 2 \left[1 - \frac{\sum_{i=1}^n (x_{ij} - \bar{x}_j)(x_{ik} - \bar{x}_k)}{s_j s_k} \right] \\ &= 2(1 - r_{jk}) \end{aligned}$$

dari jarak euclid di atas diperoleh matriks jarak kuadrat

$$d_{ij}^2 = \begin{bmatrix} 0 & d_{12} & \cdots & d_{1n} \\ d_{21} & 0 & \cdots & d_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ d_{n1} & d_{n2} & \cdots & 0 \end{bmatrix} \text{ disebut matriks dissimilaritas}$$

Diberikan suatu matriks data dengan n baris (himpunan subyek dari 8 jenis mesin textile) dan p kolom (himpunan variabel dari 6 minggu)

	A	B	C	D	E	F
1	12	20	5	12	7	12
2	3	10	3	4	6	6
3	4	3	3	3	4	7
4	4	5	4	3	12	4
5	7	2	4	4	4	7
6	6	3	2	2	3	2
7	2	2	2	2	2	6
8	2	3	1	2	2	4
Σ	40	48	24	32	40	48
\bar{X}	5	6	3	4	5	6

Mencari jarak antara dua elemen d_{ij}^2 :

$$r_{ij} = \frac{s_{ij}}{s_{ii} s_{jj}}$$

Produk Momen Korelasi

$$r_{11} = \frac{s_{11}^2}{s_{11} s_{11}} = 1 \quad r_{11} = r_{22} = r_{33} = r_{44} = r_{55} = r_{66} = 1$$

$$r_{12} = \frac{s_{12}}{s_{11} s_{22}} = \frac{13}{\sqrt{9,75} \sqrt{34}} = 0,71$$

$$r_{13} = 0,75 \quad r_{23} = 0,63 \quad r_{34} = 0,75 \quad r_{46} = 0,88$$

$$r_{14} = 0,87 \quad r_{24} = 2,38 \quad r_{35} = 0,29 \quad r_{56} = 0,15$$

$$r_{15} = 0,27 \quad r_{25} = 1,03 \quad r_{36} = 0,1$$

$$r_{16} = 0,67 \quad r_{26} = 0,75 \quad r_{45} = 0,36$$

dari varian, covarian dan produk momen korelasi,

$$d_{11} = d_{22} = d_{33} = d_{44} = d_{55} = d_{66} = 0$$

$$d_{12} = 2(1 - r_{12}) = 0,58$$

$$d_{13} = 0,5$$

$$d_{ij}^2 = \begin{bmatrix} 0 & 0,58 & 0,5 & 0,26 & 1,46 & 0,66 \\ 0,58 & 0 & 0,74 & -2,76 & -0,06 & 0,5 \\ 0,5 & 0,74 & 0 & 0,5 & 1,42 & 1,8 \\ 0,26 & -2,76 & 0,5 & 0 & 2,28 & 0,26 \\ 1,46 & -0,06 & 1,42 & 1,28 & 0 & 1,7 \\ 0,66 & 0,5 & 1,8 & 0,26 & 1,7 & 0 \end{bmatrix}$$

d_{ij}^2 = menggambarkan hubungan fungsional antara variabel ke-*i* dan variabel ke-*j*

2.1 Metode Clustering

Di dalam tugas akhir ini pemecahan permasalahan analisa cluster digunakan metode clustering hierarchical.

Metode Clustering Hierarchical

Metode ini menggunakan struktur yang sama. Dengan memberikan inisial pada n cluster yang menghubungkan n elemen dalam N, didefinisikan jarak $d_{J_i J_j}^2$, antara dua cluster J_i dan J_j dalam model tertentu. Dengan menggunakan jarak ini dua cluster dikelompokkan menjadi satu cluster.

J_i dan J_j adalah dua cluster yang dikelompokkan menjadi satu cluster

$$d_{J_i J_j}^2 = \min_{r,s} d_{J_r J_s}^2$$

Definisi 2.1

$p \in J_i$ dan $q \in J_j$ adalah dua cluster yang dikelompokkan menjadi satu cluster

jika $d_{J_i J_j}^2 = \min_{\substack{p \in J_i \\ q \in J_j}} d_{pq}^2$ merupakan metode persekitaran terdekat.

Definisi 2.2

$p \in J_i$ dan $q \in J_j$ adalah dua cluster yang dikelompokkan menjadi satu cluster

jika $d_{J_i J_j}^2 = \max_{\substack{p \in J_i \\ q \in J_j}} d_{pq}^2$ merupakan metode persekitaran terjauh.

Definisi 2.3

$\bar{X}_{J_i} = \frac{1}{n_i} \sum_{p \in J_i} X_p$ dan $\bar{X}_{J_j} = \frac{1}{n_j} \sum_{q \in J_j} X_q$ adalah dua cluster yang dikelompokkan

menjadi satu cluster sehingga diperoleh metode terpusat (metode sentroid)

$$d_{J_i J_j}^2 = \frac{n_i n_j}{n_i + n_j} (\bar{X}_{J_i} - \bar{X}_{J_j})' (\bar{X}_{J_i} - \bar{X}_{J_j})$$

dimana : $d_{J_i J_j}^2$ = Kuadrat Jarak Euclid antara \bar{X}_{J_i} dan \bar{X}_{J_j} .

Dari definisi 2.1 akan dicari jarak terpendek dari data matriks d_g^2 dengan metode persekitaran tedekat. Diberikan ilustrasi dari sebuah pabrik textile mempunyai 6 jenis mesin tenun. Dengan menggunakan matriks d_g^2 elemen-elemen dalam matriks tersebut menggambarkan hubungan antar variabel sehingga akan digunakan untuk menetapkan tingkat produksi yang optimal dengan efisiensi waktu. Disajikan dalam contoh aplikasi sebagai berikut :

$$((d_{ij}^2)) = \begin{bmatrix} 0 & 8 & 9 & 4 & 7 & 7 \\ 8 & 0 & 3 & 7 & 4 & 5 \\ 9 & 3 & 0 & 8 & 3 & 5 \\ 4 & 7 & 8 & 0 & 7 & 6 \\ 7 & 4 & 3 & 7 & 0 & 6 \\ 7 & 5 & 5 & 6 & 6 & 0 \end{bmatrix}$$

Langkah 1 : mencari jarak terpendek $d_{j_1 j_1}^2 = \min_{\substack{p \in J_1 \\ q \in J_1}} d_{pq}^2$

$$d_{12}^2 = 8 \quad d_{13}^2 = 9 \quad d_{14}^2 = 4 \quad d_{15}^2 = 7$$

$$d_{16}^2 = 5 \quad d_{23}^2 = 3 \quad d_{24}^2 = 7 \quad d_{25}^2 = 4$$

$$d_{26}^2 = 5 \quad d_{34}^2 = 8 \quad d_{35}^2 = 3 \quad d_{36}^2 = 5$$

$$d_{45}^2 = 7 \quad d_{46}^2 = 7 \quad d_{56}^2 = 6$$

didapatkan $d_{23}^2 = 3$ jarak terpendek selanjutnya elemen {2} dan elemen {3}

dipadatkan dalam satu cluster sehingga didapat $J_1 = \{1\}$, $J_2 = \{2,3\}$, $J_3 = \{4\}$, $J_4 = \{5\}$,

$J_5 = \{6\}$. kemudian digunakan metoda persekitaran terdekat

$$d_{j_1 j_1}^2 = \min_{\substack{p \in J_1 \\ q \in J_1}} \{ d_{pq}^2 \} \quad d_{j_1 j_1}^2 = \min_{\substack{p \in \{2,3\} \\ q \in \{1\}}} \{ d_{12}^2, d_{13}^2 \} = \min \{ 8, 9 \} = 8$$

$$d_{j_1 j_1}^2 = \min_{\substack{p \in \{2,3\} \\ q \in \{4\}}} \{ d_{24}^2, d_{34}^2 \}$$

$$= \min \{ 7, 8 \}$$

$$= 7$$

$$d_{j_1 j_1}^2 = \min_{\substack{p \in \{2,3\} \\ q \in \{5\}}} \{ d_{25}^2, d_{35}^2 \}$$

$$= \min\{3,3\}$$

$$= 3$$

$$d_{j_1 j_1}^2 = \min_{\substack{p \in \{2,3\} \\ q \in 6}} \{ d_{26}^2, d_{36}^2 \}$$

$$= \min\{5,5\}$$

$$= 5$$

kemudian dibentuk matriks baru dengan menggunakan jarak kuadrat di atas dan matriks dinotasikan dengan $((d_{ij(1)}^2))$ dan i,j meneruskan ke-i dan ke-j. Matriks diberikan seperti di bawah:

$$((d_{ij(1)}^2)) = \begin{bmatrix} \{1\} & \{2,3\} & \{4\} & \{5\} & \{6\} \\ 0 & 8 & 4 & 7 & 7 \\ 8 & 0 & 7 & 3 & 5 \\ 4 & 7 & 0 & 7 & 6 \\ 7 & 3 & 7 & 0 & 6 \\ 7 & 5 & 6 & 6 & 0 \end{bmatrix}$$

Langkah 2 :

Dari jarak kuadrat di atas didapat $d_{j_1 j_1}^2 = \min d_{ij}^2 = d_{23(5)}^2 = 3$.

sebagai jarak terpendek selanjutnya cluster $\{2,3\}$ dan elemen $\{5\}$ dipadatkan dalam satu cluster sehingga didapatkan $J_1=\{1\}$, $J_2=\{2,3,5\}$, $J_3=\{4\}$, $J_5=\{6\}$. Kemudian digunakan metoda persekitaran terdekat:

$$d_{j_1 j_2(2)}^2 = \min_{\substack{p \in J_1(2) \\ q \in J_2(2)}} \{ d_{pq(2)}^2 \}$$

Kemudian dibentuk matriks baru dengan menggunakan jarak kuadrat di atas dan matriks dinotasikan dengan $((d_{ij(2)}^2))$ dan i,j meneruskan ke-i dan ke-j.

Matriks diberikan seperti di bawah ini :

$$((d_{ij(2)}^2)) = \begin{bmatrix} \{1\} & \{2,3,5\} & \{4\} & \{6\} \\ 0 & 7 & 4 & 7 \\ 7 & 0 & 7 & 5 \\ 4 & 7 & 0 & 6 \\ 7 & 5 & 6 & 0 \end{bmatrix}$$

Langkah 3 :

Dari jarak kuadrat di atas didapat $d_{j_1j_1}^2 = \min d_{ij}^2 = d_{14}^2 = 4$.

Sebagai jarak terpendek selanjutnya elemen {1} dan elemen {4} dipadatkan dalam satu cluster sehingga didapatkan $J_1=\{1,4\}$, $J_2=\{2,3,5\}$, $J_3=\{6\}$. Kemudian digunakan metoda persekitaran terdekat:

$$d_{j_1j_1(3)}^2 = \min_{\substack{p \in J_{1(3)} \\ q \in J_{J(3)}}} \{ d_{pq(3)}^2 \}$$

Kemudian dibentuk matriks baru dengan menggunakan jarak kuadrat di atas dan matriks dinotasikan dengan $((d_{ij(3)}^2))$ dan i,j meneruskan ke-i dan ke-j. Matriks diberikan seperti di bawah ini:

$$((d_{ij(3)}^2)) = \begin{bmatrix} \{1,4\} & \{2,3,5\} & \{6\} \\ 0 & 7 & 6 \\ 7 & 0 & 5 \\ 6 & 5 & 0 \end{bmatrix}$$

Langkah 4 :

Dari jarak kuadrat di atas didapat $d_{ij}^2 = \min d_{ij}^2 = d_{(235)(6)}^2 = 5$.

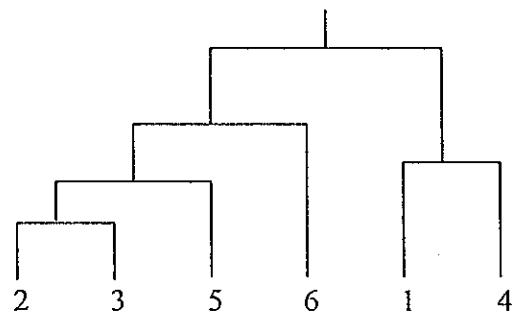
sebagai jarak terpendek selanjutnya elemen {2,3,5} dan elemen {6} dipadatkan dalam satu cluster sehingga didapatkan $J_1 = \{1,4\}$, $J_2 = \{2,3,5,6\}$. kemudian digunakan metoda persekitaran terdekat:

$$d_{ij(4)}^2 = \min_{\substack{p \in J_{i(4)} \\ q \in J_{j(4)}}} \{ d_{pq}^2 \}$$

kemudian dibentuk matriks baru dengan menggunakan jarak kuadrat di atas dan matriks dinotasikan dengan $((d_{ij(4)}^2))$ dan i,j meneruskan ke-i dan ke-j. Matriks diberikan seperti di bawah ini:

$$\begin{matrix} & \{1,4\} & \{2,3,5,6\} \\ ((d_{ij(4)}^2)) = & \begin{bmatrix} 0 & 7 \\ 7 & 0 \end{bmatrix} \end{matrix}$$

Langkah 5: didapatkan jarak terpendek $d_{14(2356)}^2 = 7$ yang digunakan untuk memadatkan elemen {1,4} kedalam cluster {2,3,5,6} sehingga semua unit termuat dalam satu cluster. Dengan langkah-langkah di atas didapat skema clustering hirarki sebagai berikut :



Skema hirarki menunjukkan urutan pengelompokkan unit-unit variabel sehingga terletak dalam satu cluster.

