

# Clustering

Ali Ridho Barakah

Workshop Data Mining

18-20 Juli 2006

Jurusan Teknologi Informasi  
Politeknik Elektronika Negeri Surabaya

# What is cluster?

a collection of objects which are  
“similar” between them and are  
“dissimilar” to the objects belonging  
to other clusters

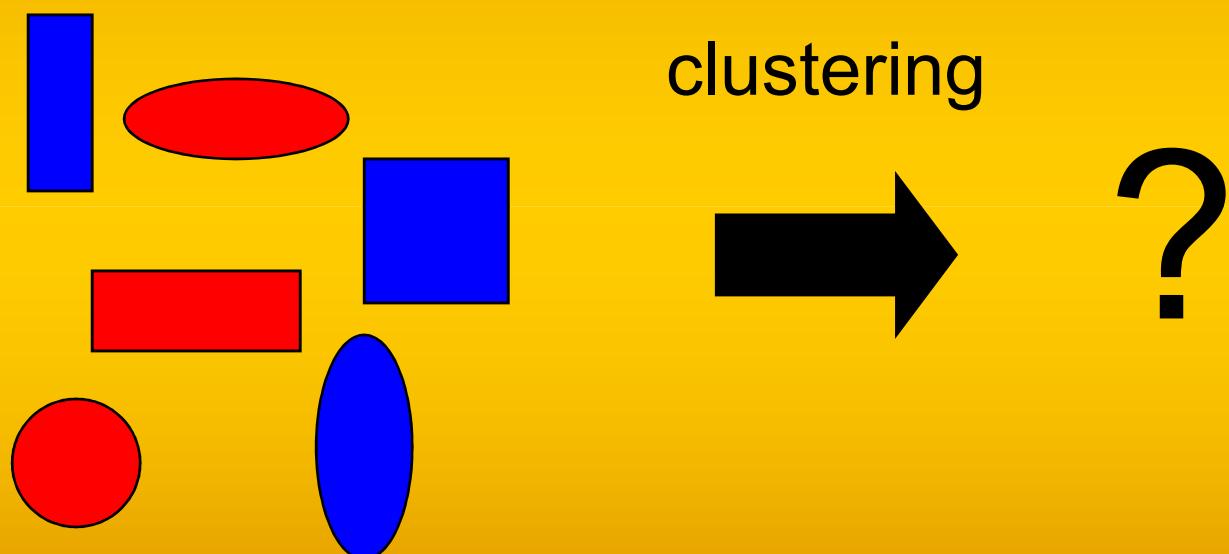
[http://www.elet.polimi.it/upload/matteucc/Clustering/tutorial\\_html/index.html](http://www.elet.polimi.it/upload/matteucc/Clustering/tutorial_html/index.html)

# What is clustering?

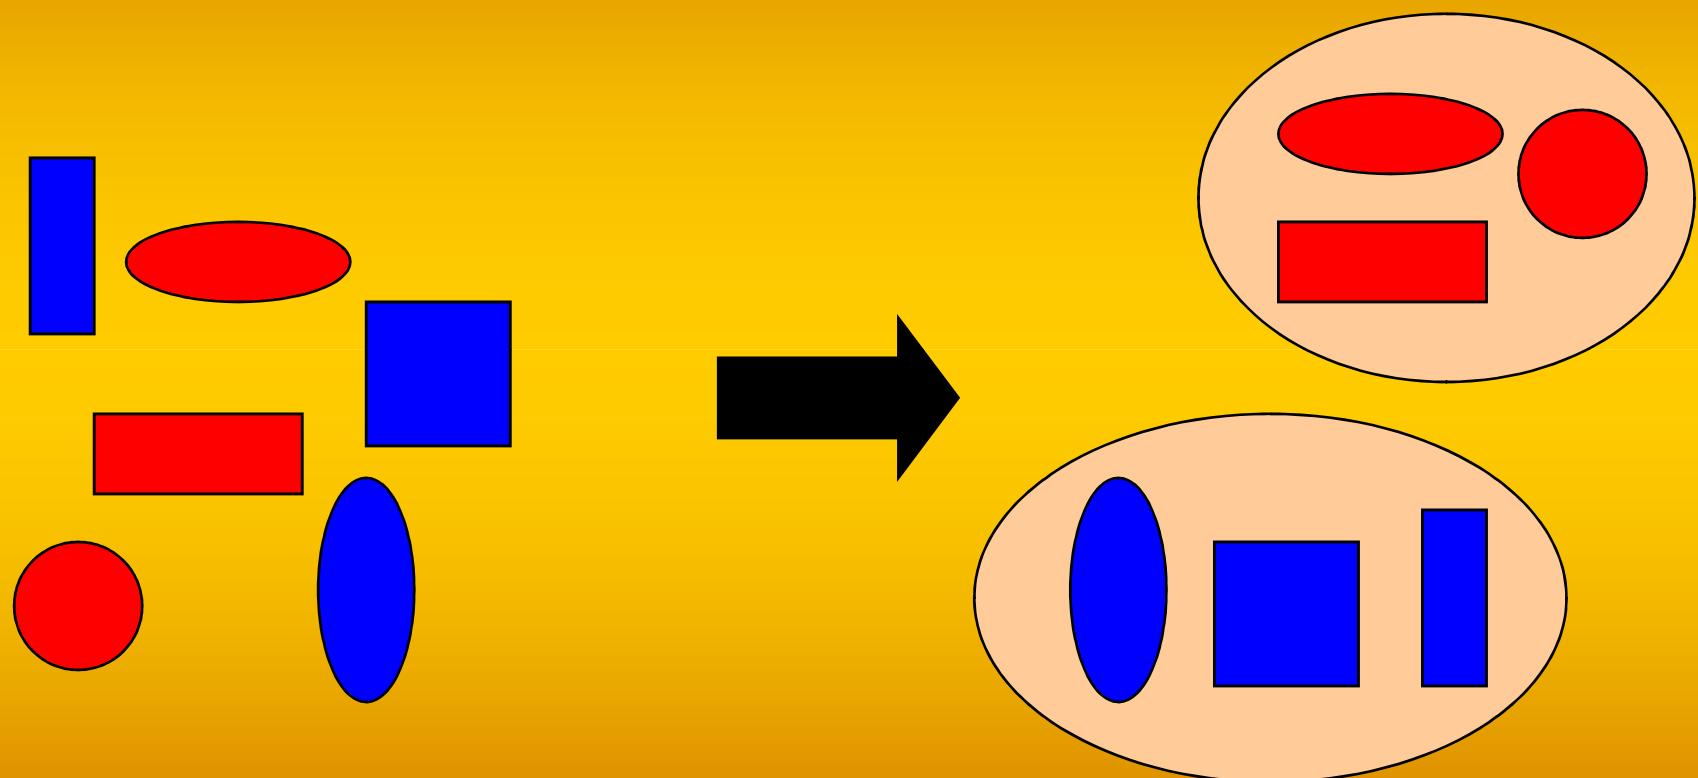
the process of organizing objects  
into groups whose members are  
similar in some way

[http://www.elet.polimi.it/upload/matteucc/Clustering/tutorial\\_html/index.html](http://www.elet.polimi.it/upload/matteucc/Clustering/tutorial_html/index.html)

# Ilustrasi clustering

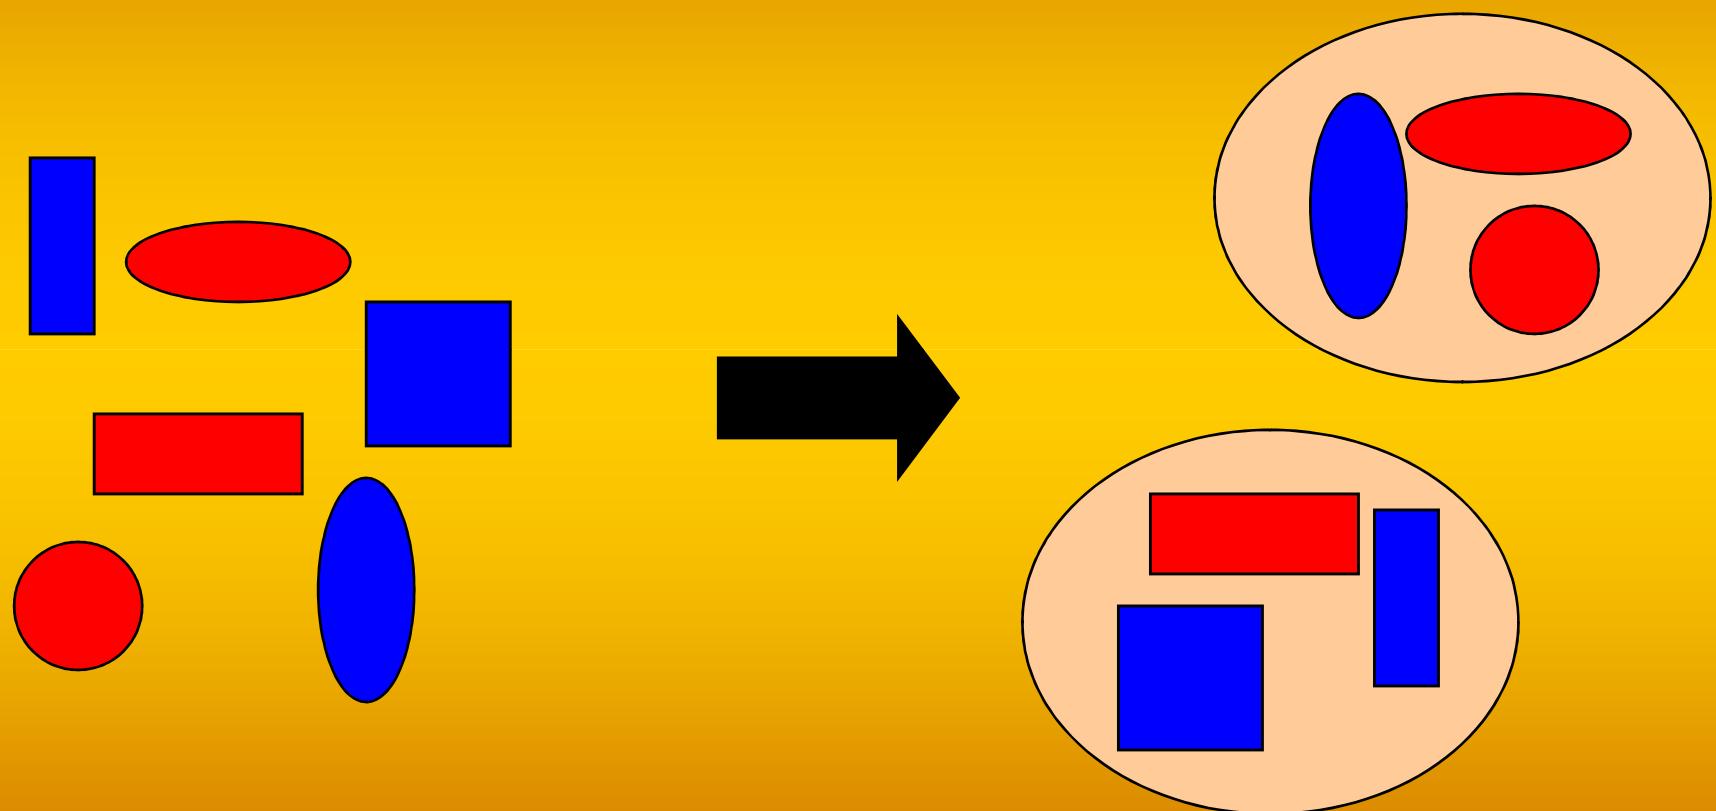


# Ilustrasi clustering



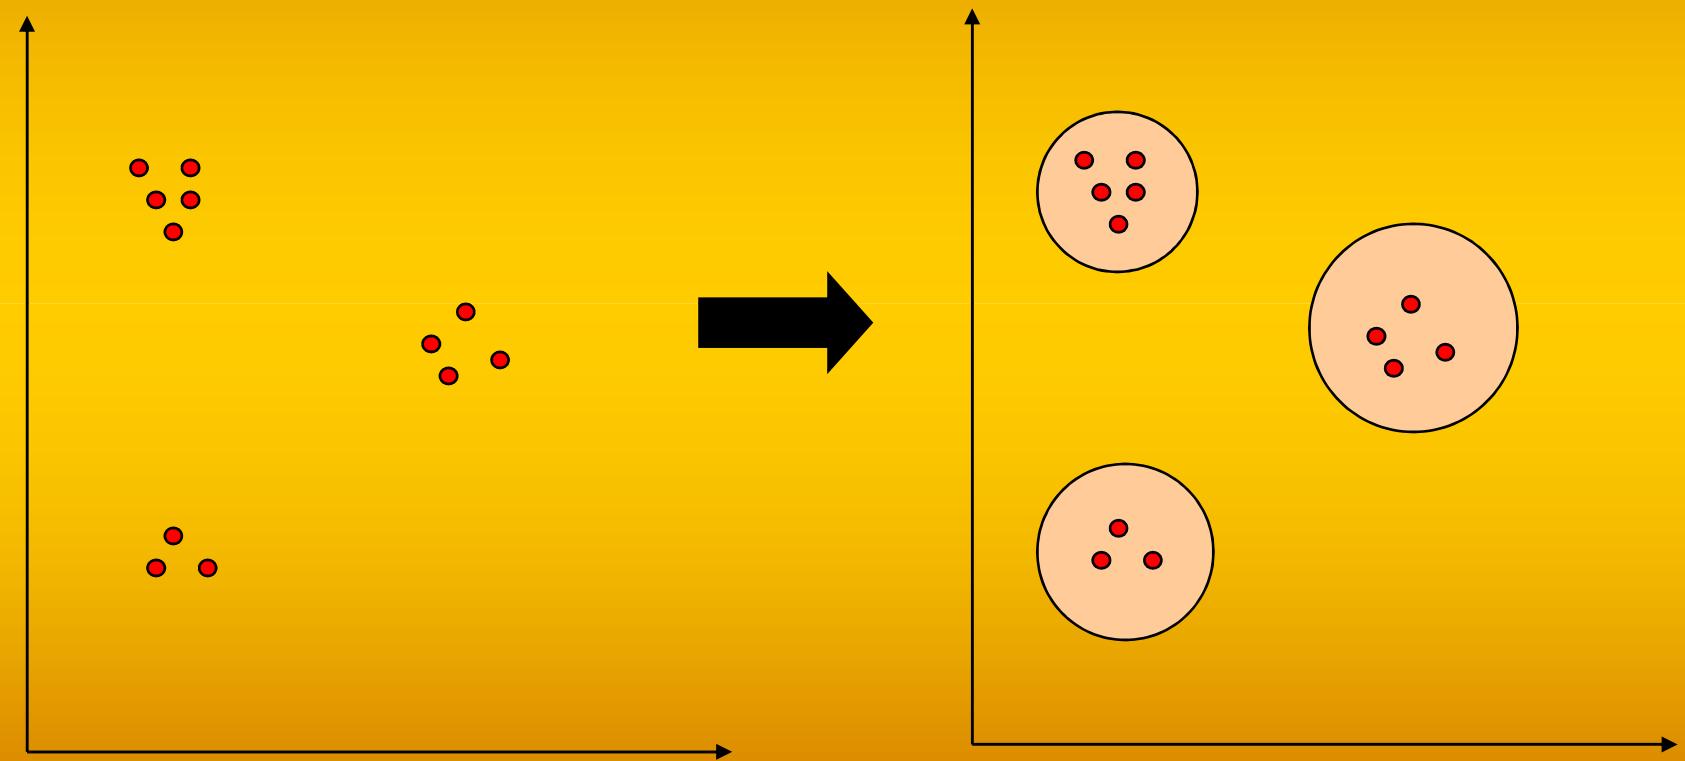
Similaritas berdasarkan warna

# Ilustrasi clustering



Similaritas berdasarkan bentuk

# Ilustrasi clustering



Similaritas berdasarkan jarak

# Clustering vs Classification

	Classification	Clustering
Data	supervised	unsupervised
Label	Ya	Tidak
Analisa hasil	Error ratio	Variance

# Classification (kasus sederhana)

Data penyakit hipertensi

Umur	Kegemukan	Hipertensi
muda	gemuk	Tidak
muda	sangat gemuk	Tidak
paruh baya	gemuk	Tidak
paruh baya	terlalu gemuk	Ya
tua	terlalu gemuk	Ya

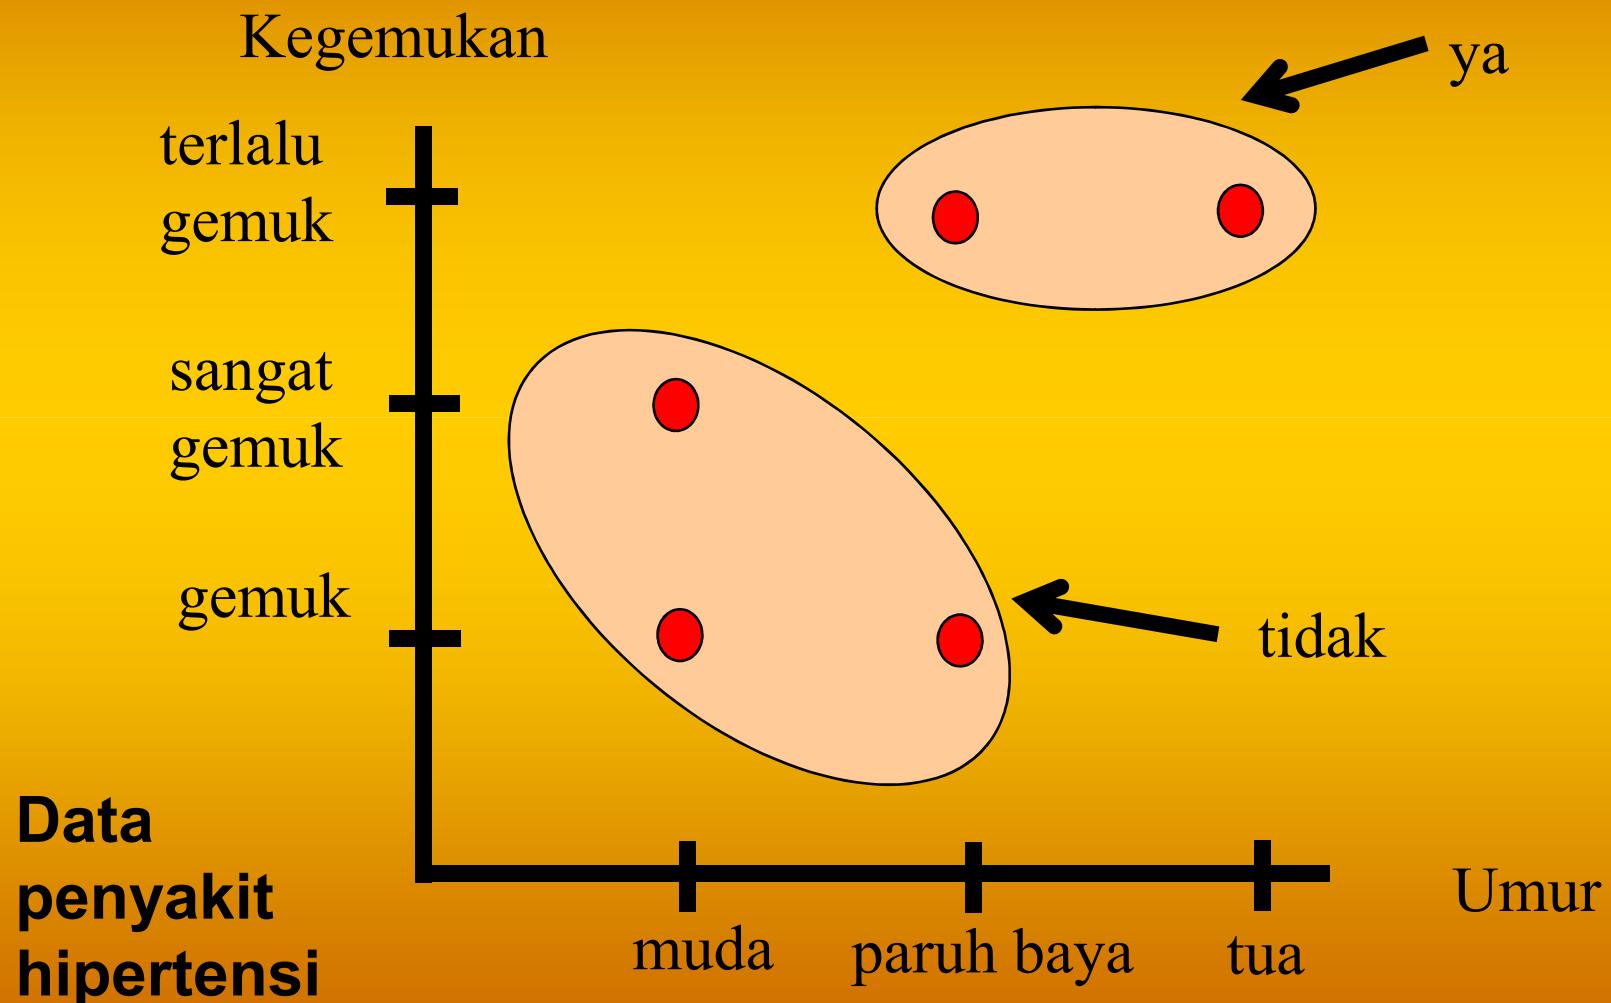
label

Supervised data

# Penyelesaian dengan Decision Tree



# Classification (kasus sederhana)



# Clustering (kasus sederhana)

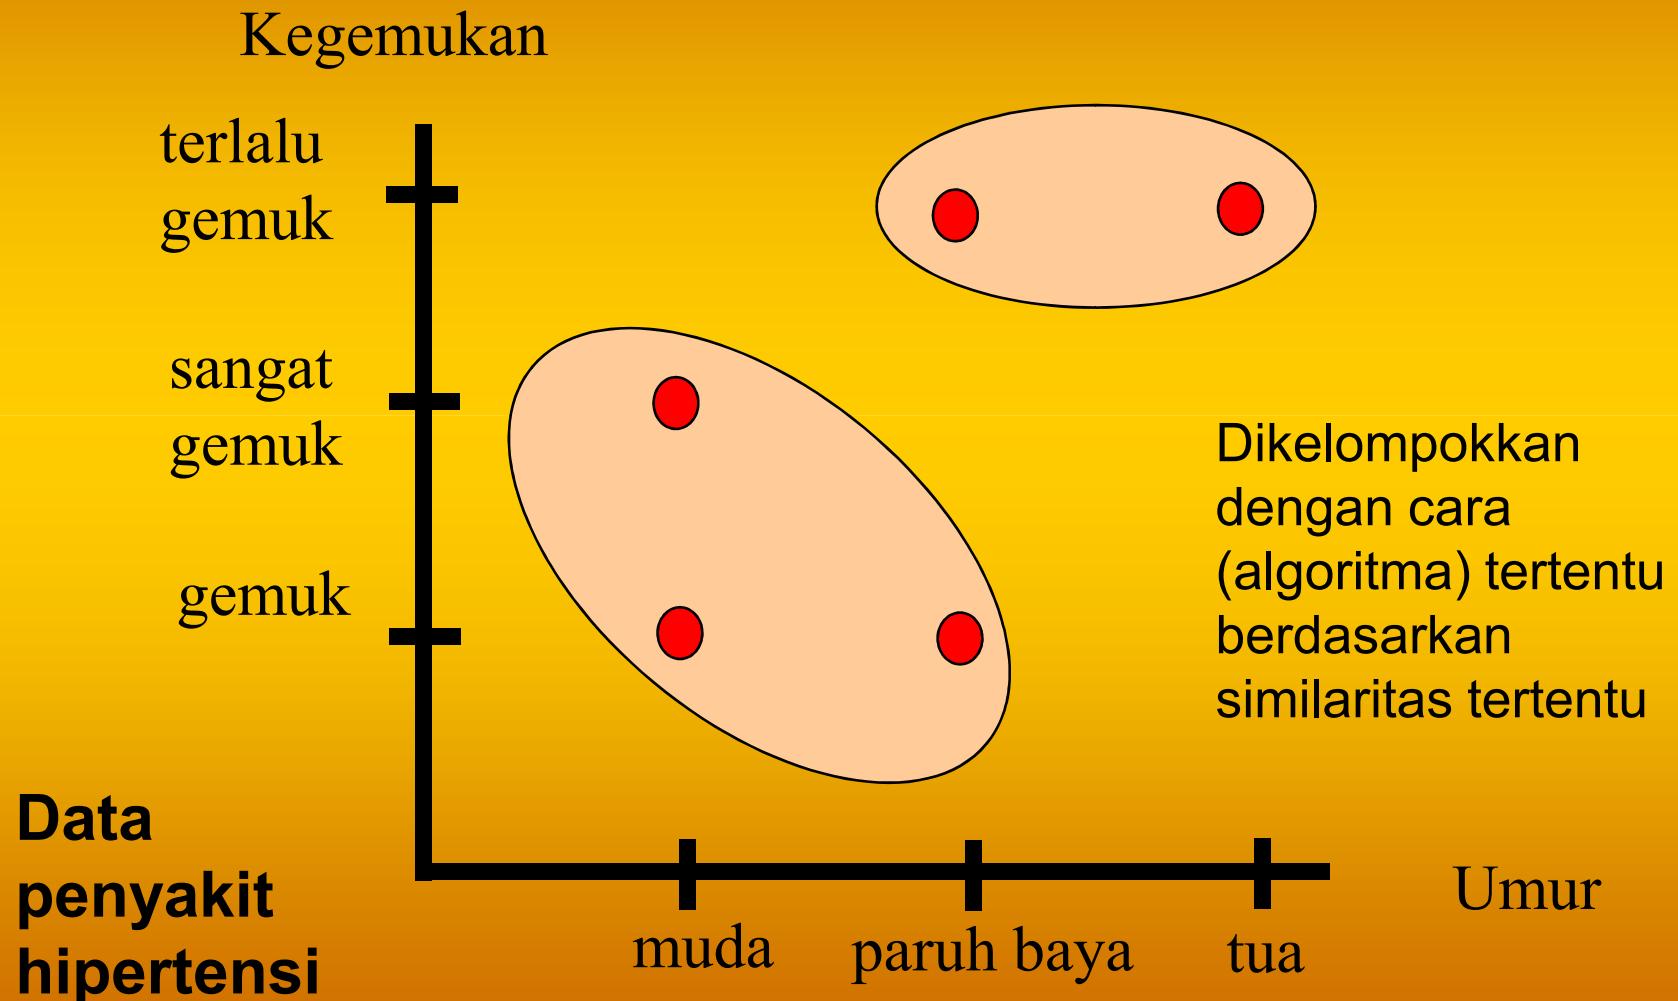
Data penyakit hipertensi

Umur	Kegemukan
muda	gemuk
muda	sangat gemuk
paruh baya	gemuk
paruh baya	terlalu gemuk
tua	terlalu gemuk

tidak ada  
label

Unsupervised data

# Clustering (kasus sederhana)



# Karakteristik clustering

- Partitioning clustering
- Hierarchical clustering
- Overlapping clustering
- Hybrid

# Partitioning clustering

- Disebut juga exclusive clustering
- Setiap data harus termasuk ke cluster tertentu
- Memungkinkan bagi setiap data yang termasuk cluster tertentu pada suatu tahapan proses, pada tahapan berikutnya berpindah ke cluster yang lain
- Contoh: K-means, residual analysis

# Overlapping clustering

- Setiap data memungkinkan termasuk ke beberapa cluster
- Data mempunyai nilai keanggotaan (membership) pada beberapa cluster
- Contoh: Fuzzy C-means, Gaussian Mixture

# Hierarchical clustering

- Setiap data harus termasuk ke cluster tertentu
- Suatu data yang termasuk ke cluster tertentu pada suatu tahapan proses, tidak dapat berpindah ke cluster lain
- Contoh: Single Linkage, Centroid Linkage, Complete Linkage, Average Centroid

# Hybrid

Mengawinkan karakteristik dari  
partitioning, overlapping dan  
hierarchical

# Algoritma-algoritma clustering

- K-means
- Single Linkage
- Centroid Linkage
- Complete Linkage
- Average Linkage
- dll

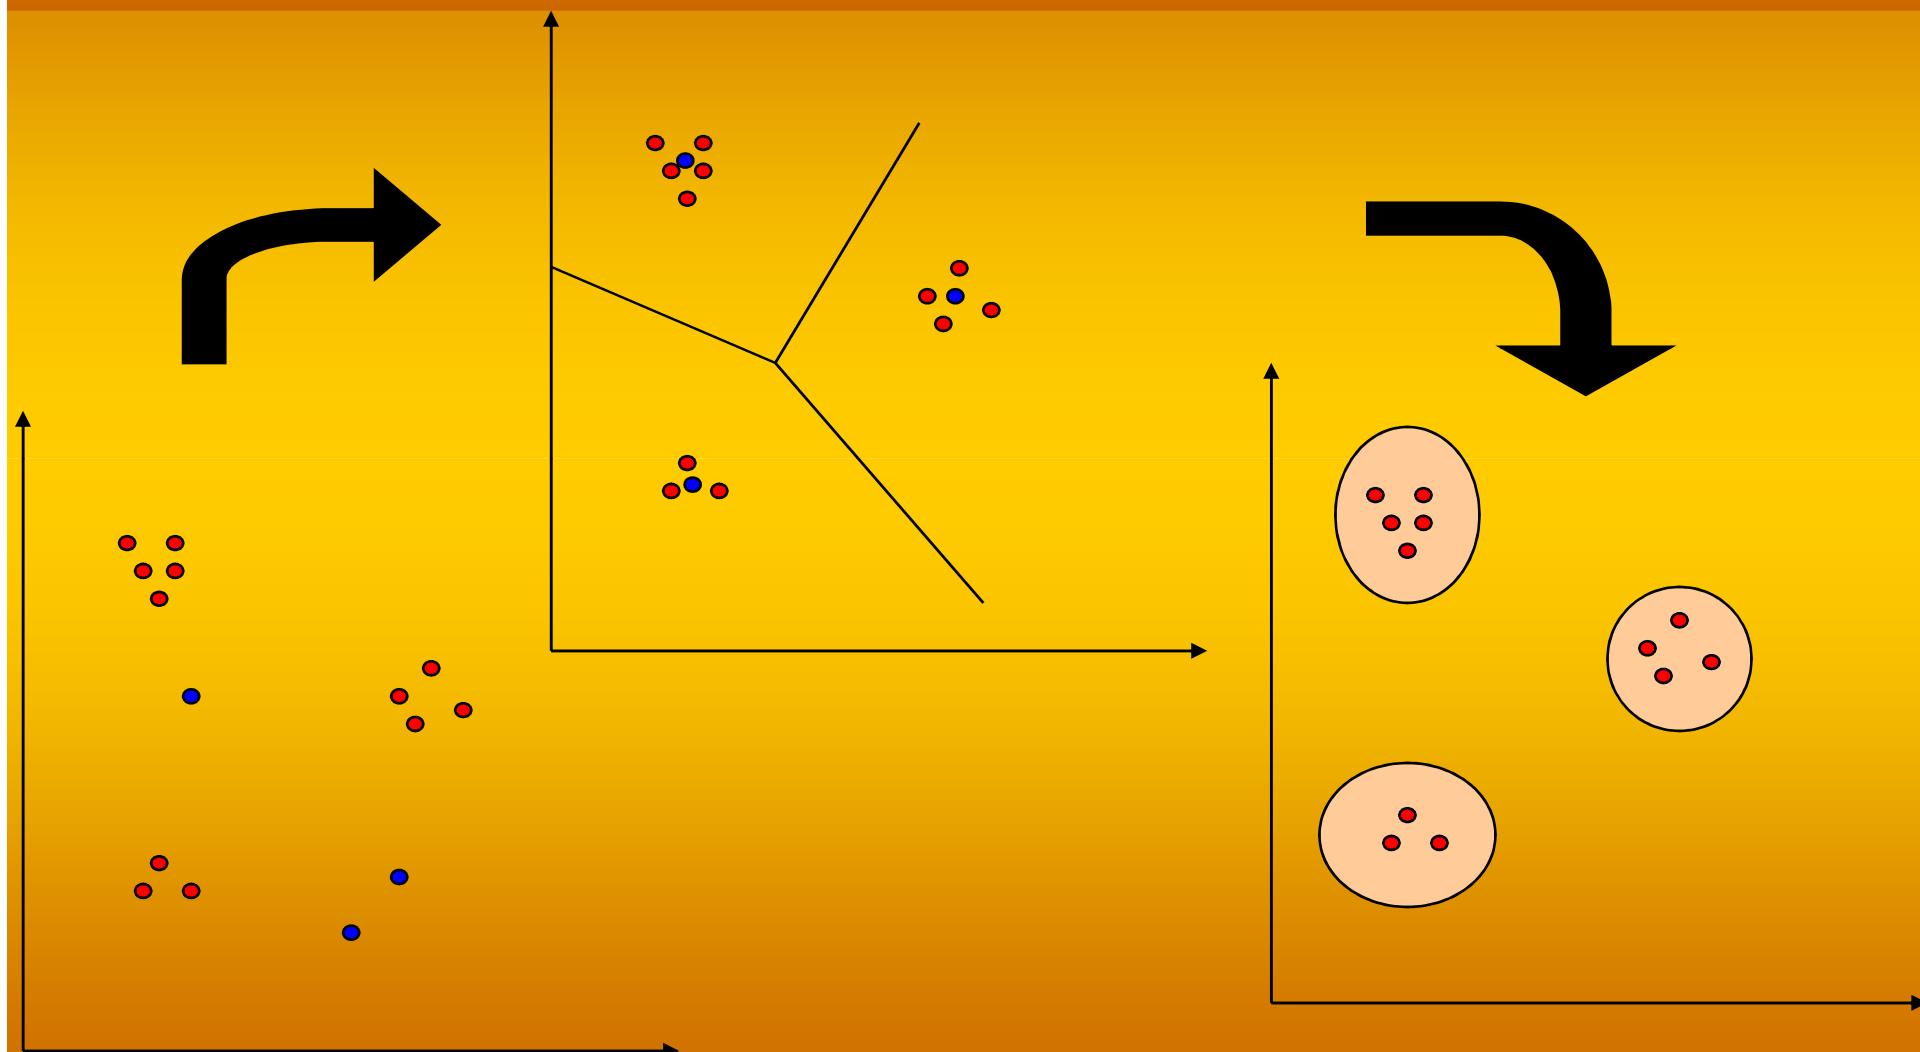
# K-means

- Termasuk partitioning clustering yang memisahkan data ke  $k$  daerah bagian yang terpisah
- K-means algorithm sangat terkenal karena kemudahan dan kemampuannya untuk mengklaster data besar dan data outlier dengan sangat cepat
- Setiap data harus termasuk ke cluster tertentu
- Memungkinkan bagi setiap data yang termasuk cluster tertentu pada suatu tahapan proses, pada tahapan berikutnya berpindah ke cluster yang lain

# Algoritma K-means

1. Tentukan  $k$  sebagai jumlah cluster yang ingin dibentuk
2. Bangkitkan  $k$  centroids (titik pusat cluster) awal secara random
3. Hitung jarak setiap data ke masing-masing centroids
4. Setiap data memilih centroids yang terdekat
5. Tentukan posisi centroids baru dengan cara menghitung nilai rata-rata dari data-data yang memilih pada centroid yang sama
6. Kembali ke langkah 3 jika posisi centroids baru dengan centroids lama tidak sama.

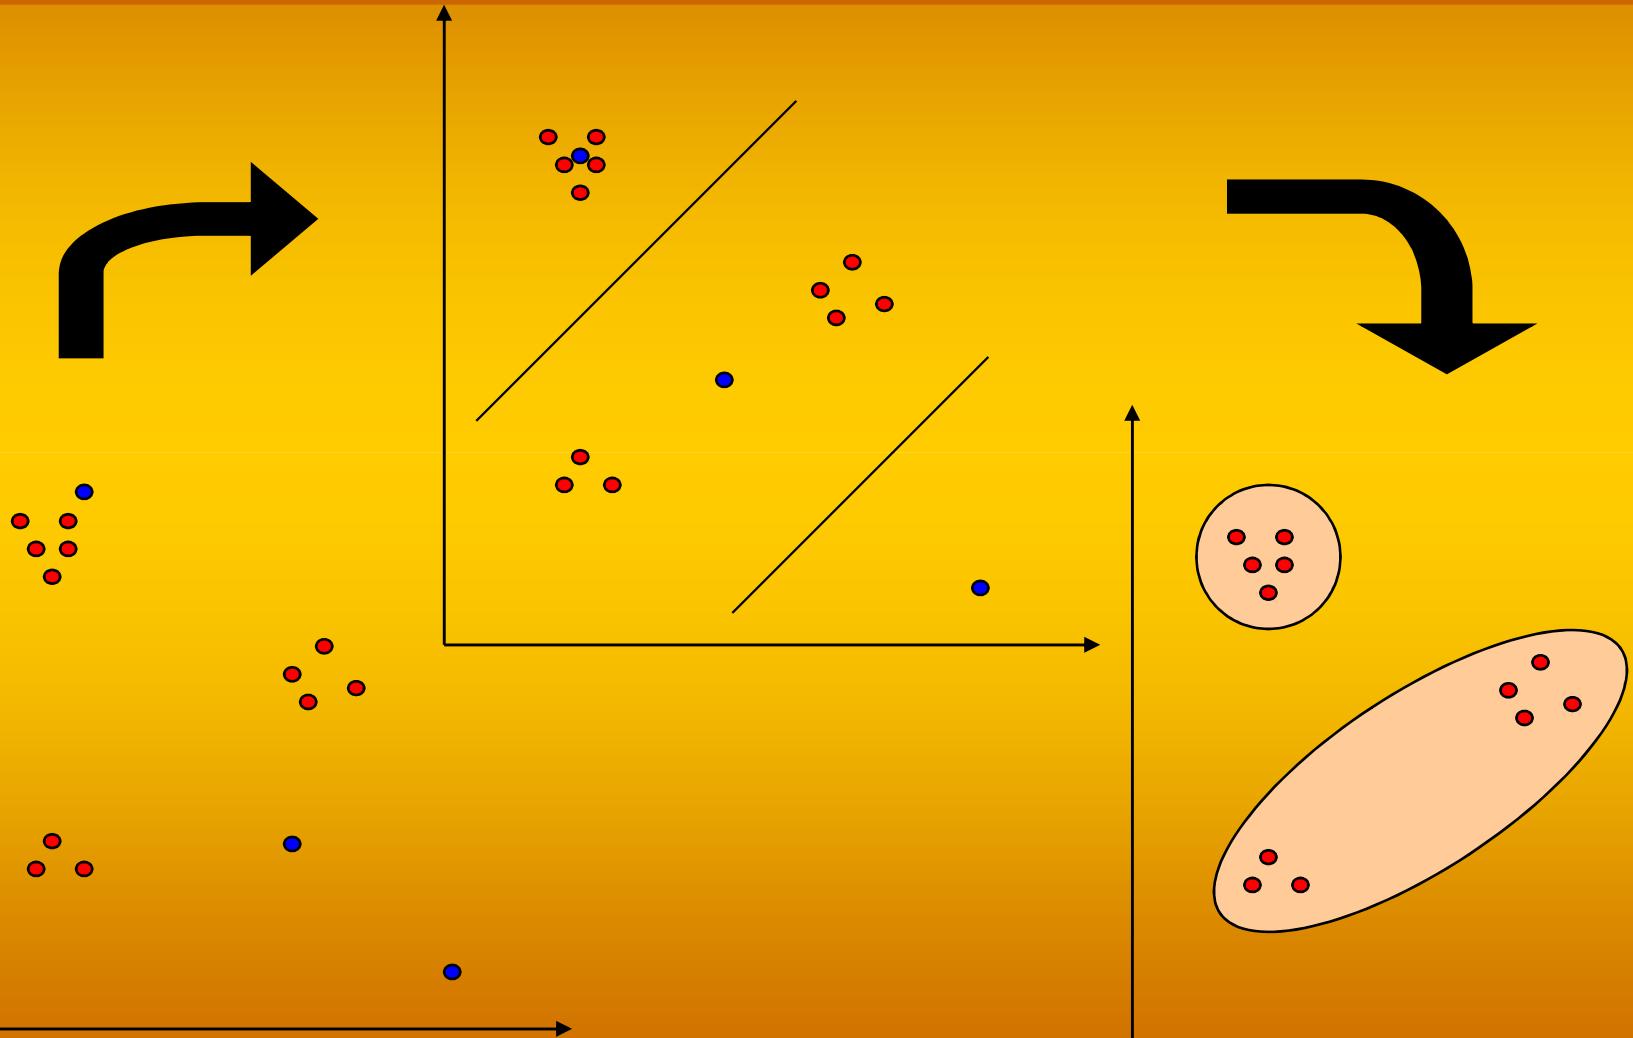
# Algoritma K-means



# Karakteristik K-means

- K-means sangat cepat dalam proses clustering
- K-means sangat sensitif pada pembangkitan centroids awal secara random
- Memungkinkan suatu cluster tidak mempunyai anggota
- Hasil clustering dengan K-means bersifat tidak unik (selalu berubah-ubah) - terkadang baik, terkadang jelek.
- K-means sangat sulit untuk mencapai global optimum

# Illustasi kelemahan K-means



# Hierarchical clustering

- Single Linkage
- Centroid Linkage
- Complete Linkage
- Average Linkage

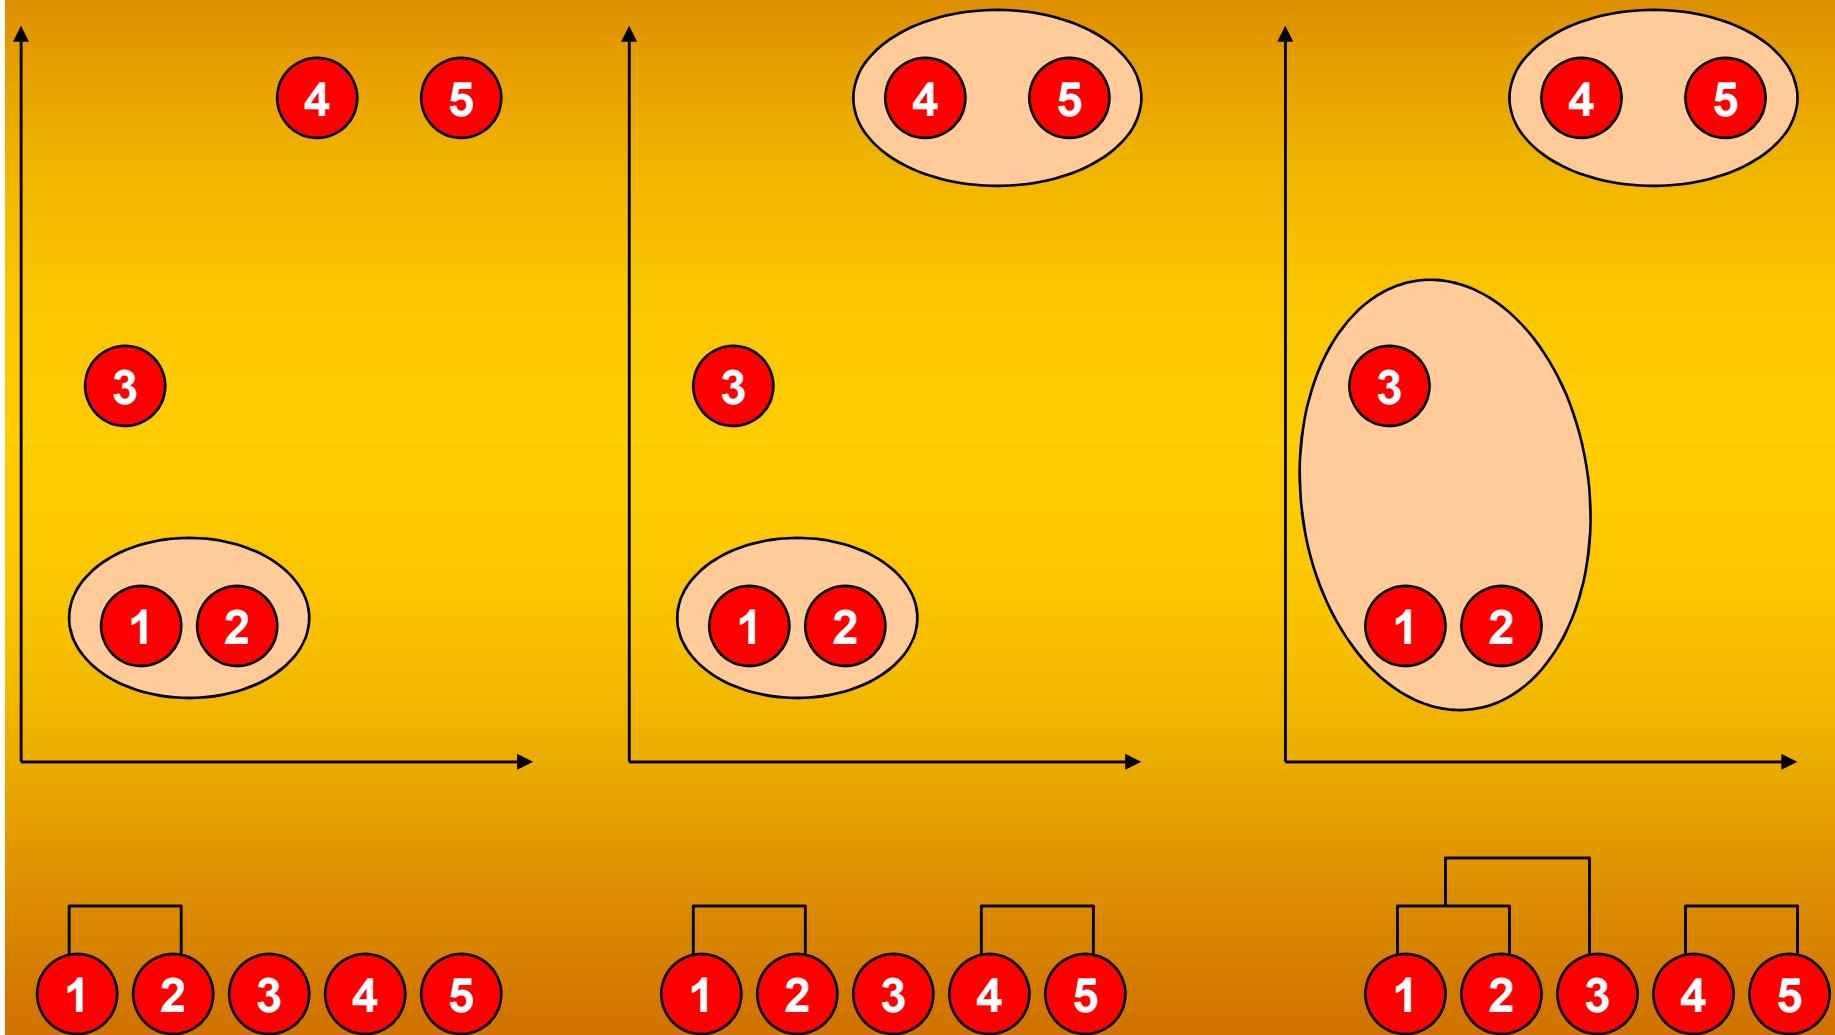
# Direction of hierarchy

- **Divisive**
  - 1 cluster to k clusters
  - Top to down division
- **Agglomerative**
  - N clusters to k clusters
  - Down to top merge

# Algoritma Hierarchical clustering

1. Tentukan  $k$  sebagai jumlah cluster yang ingin dibentuk
2. Setiap data dianggap sebagai cluster. Kalau  $N$ =jumlah data dan  $n$ =jumlah cluster, berarti ada  $n=N$ .
3. Hitung jarak antar cluster
4. Cari 2 cluster yang mempunyai jarak antar cluster yang paling minimal dan gabungkan (berarti  $n=n-1$ )
5. Jika  $n>k$ , kembali ke langkah 3

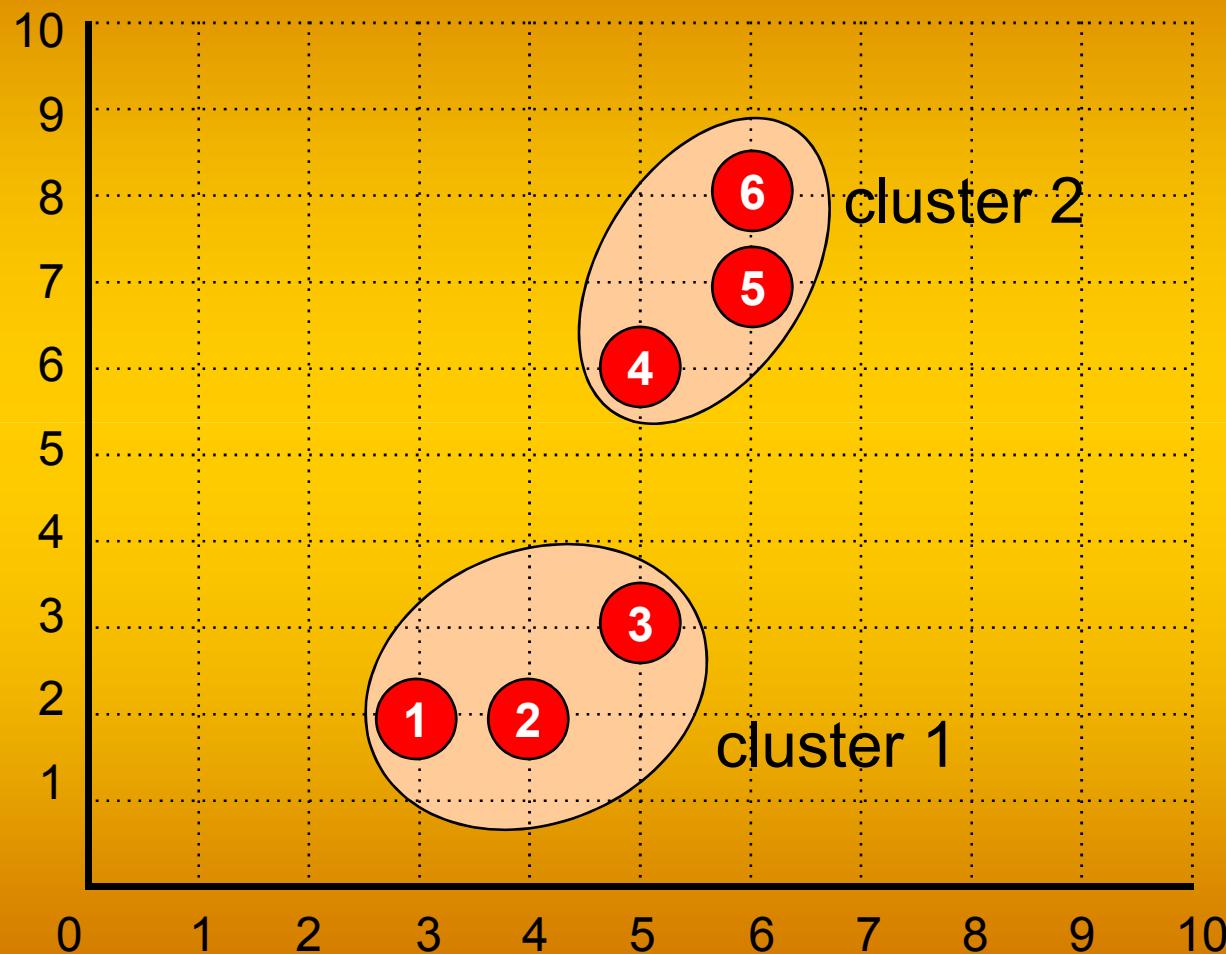
# Algoritma Hierarchical clustering



# Similarity between clusters?

- Single Linkage
  - Minimum distance between cluster
- Centroid Linkage
  - Centroid distance between cluster
- Complete Linkage
  - Maximum distance between cluster
- Average Linkage
  - Average distance between cluster

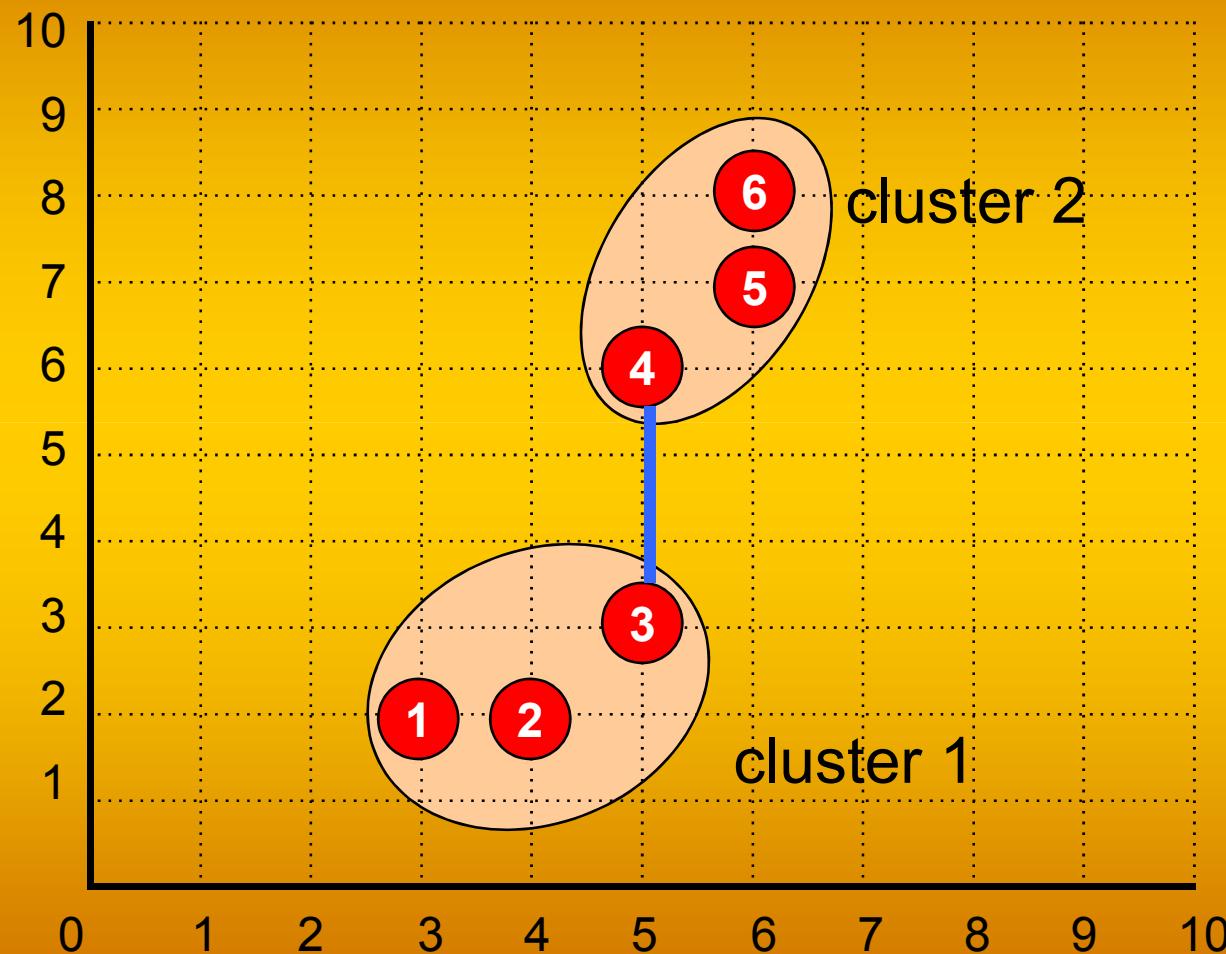
# Pengukuran jarak



Berapa jarak  
cluster 1 ke  
cluster 2

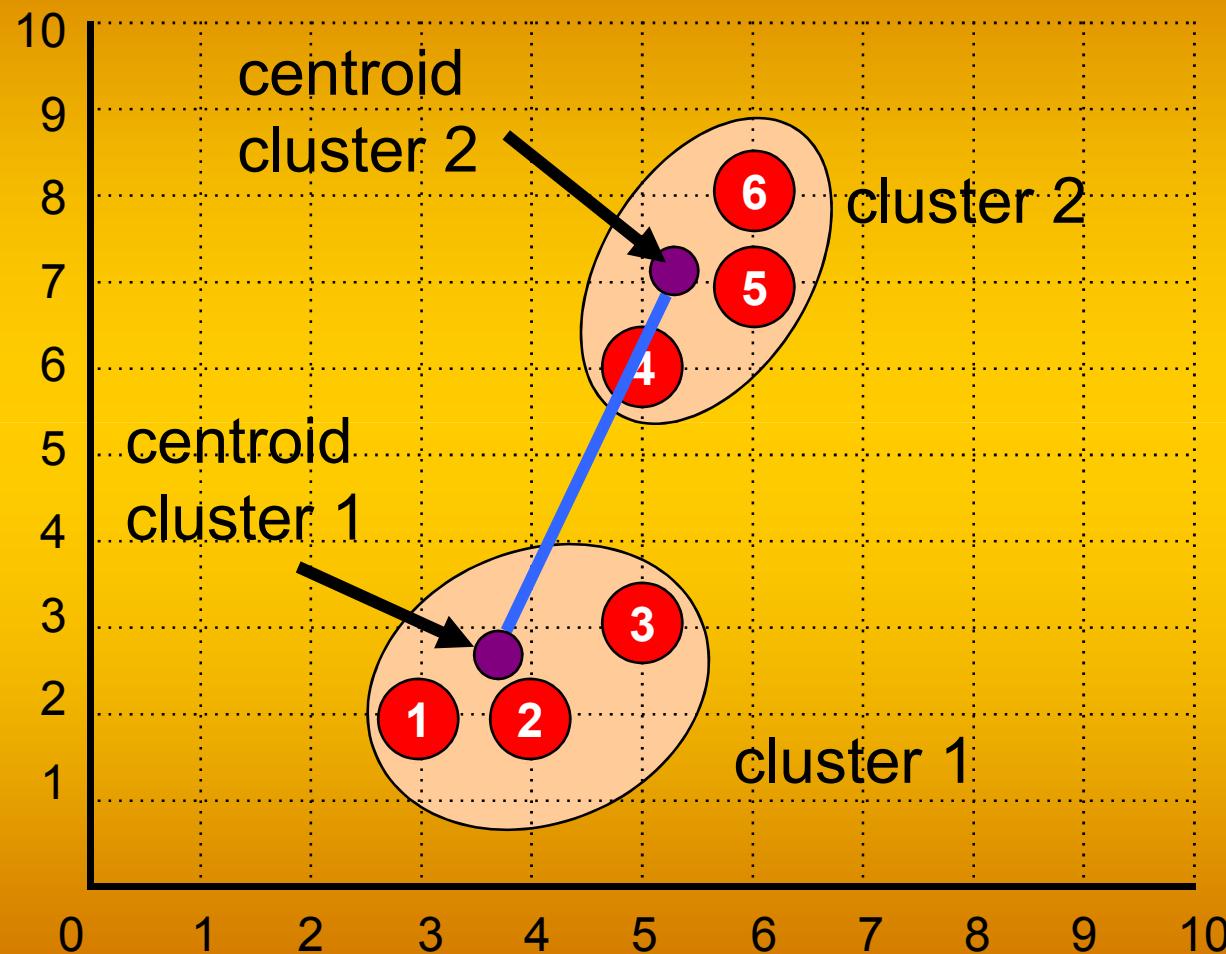
?

# Single Linkage



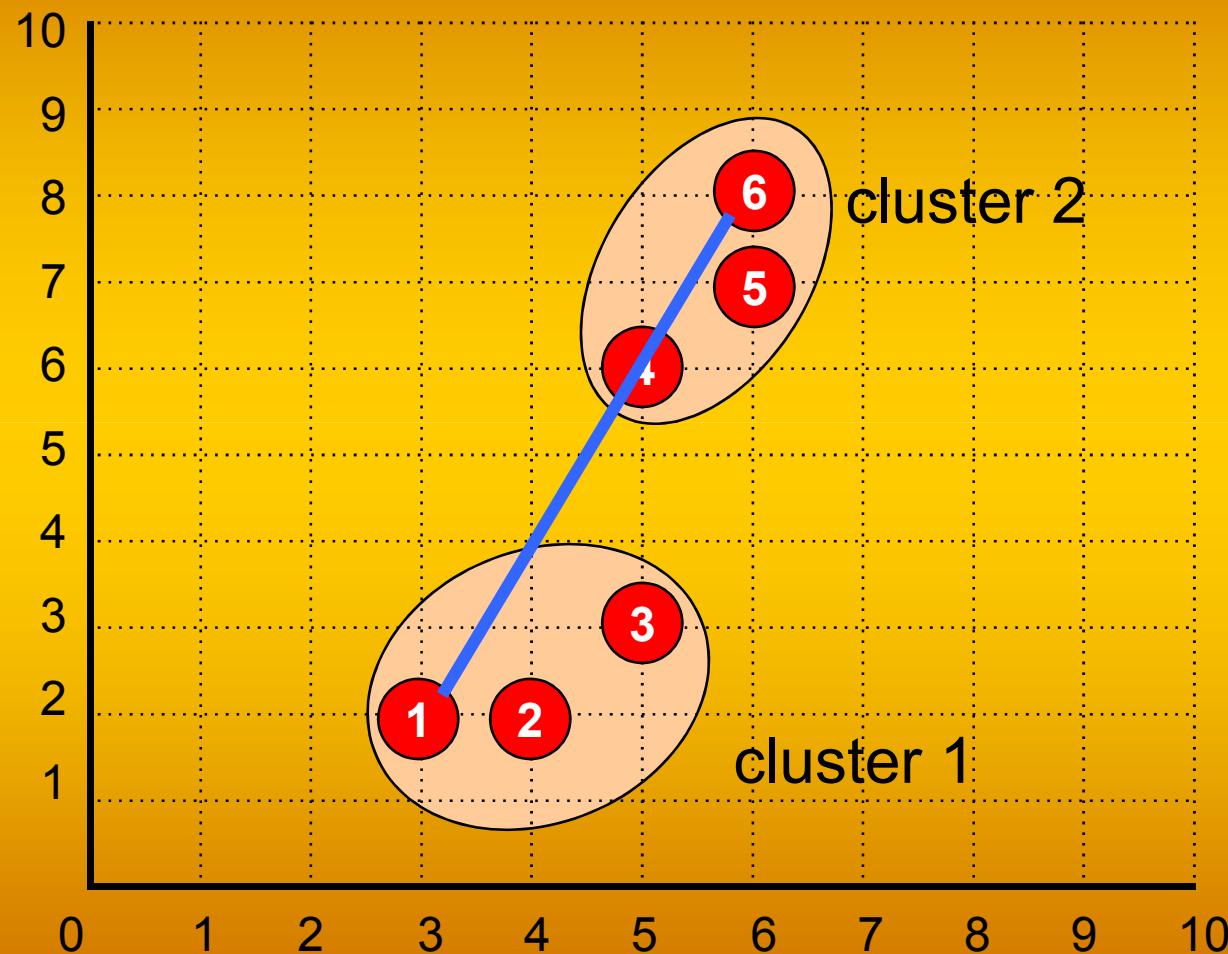
Jarak cluster 1  
ke cluster 2  
=  
Jarak data 3 ke  
data 4

# Centroid Linkage



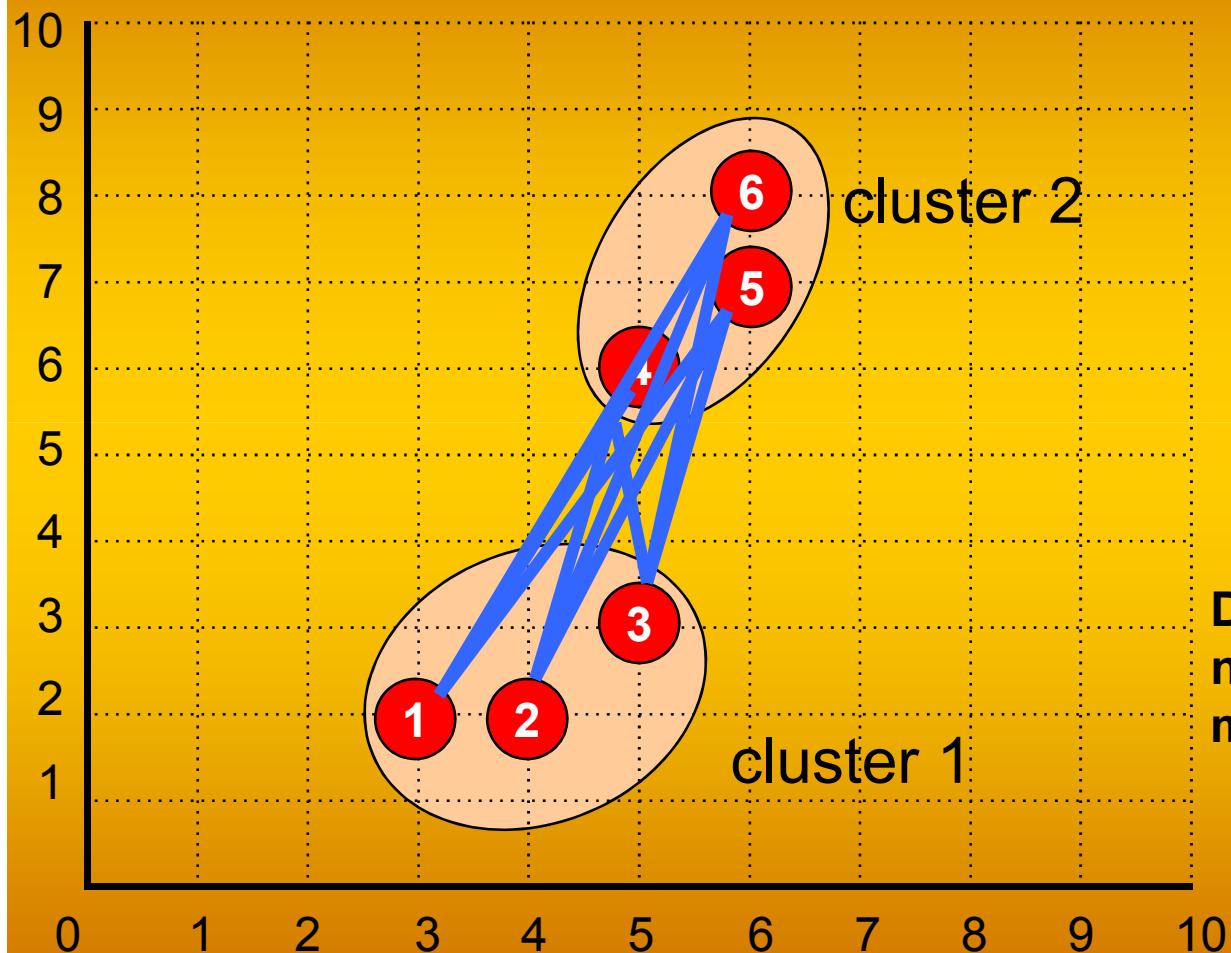
Jarak cluster 1 ke  
cluster 2  
=  
Jarak centroid  
cluster 1 ke  
centroid cluster 2

# Complete Linkage



Jarak cluster 1  
ke cluster 2  
=  
Jarak data 1 ke  
data 6

# Average Linkage



$$\text{Jarak cluster 1 ke cluster 2} = \frac{\sum \text{Jarak antar data}}{n \times m}$$

Dimana:  
n=jumlah data pada cluster 1  
m=jumlah data pada cluster 2

# Hierarchical Clustering & Dataset

- **Single Linkage**

Metode ini sangat cocok untuk dipakai pada kasus shape independent clustering, karena kemampuannya untuk membentuk pattern tertentu dari cluster. Untuk kasus condensed clustering, metode ini tidak bagus.

- **Centroid Linkage**

Metode ini baik untuk kasus clustering dengan normal data set distribution. Akan tetapi, metode ini tidak cocok untuk data yang mengandung outlier.

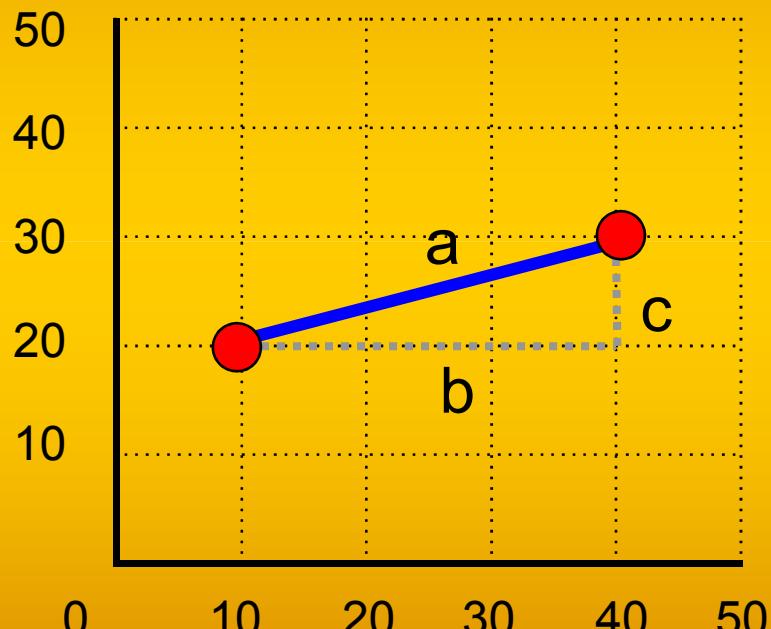
- **Complete Linkage**

Metode ini sangat ampuh untuk memperkecil variance within cluster karena melibatkan centroid pada saat penggabungan antar cluster. Metode ini juga baik untuk data yang mengandung outlier.

- **Average Linkage**

Metode ini relatif yang terbaik dari metode-metode hierarchical. Namun, ini harus dibayar dengan waktu komputasi yang paling tinggi dibandingkan dengan metode-metode hierarchical yang lain.

# Penghitungan jarak (Euclidian distance)



$$a^2 = b^2 + c^2$$

$$a = \sqrt{b^2 + c^2}$$

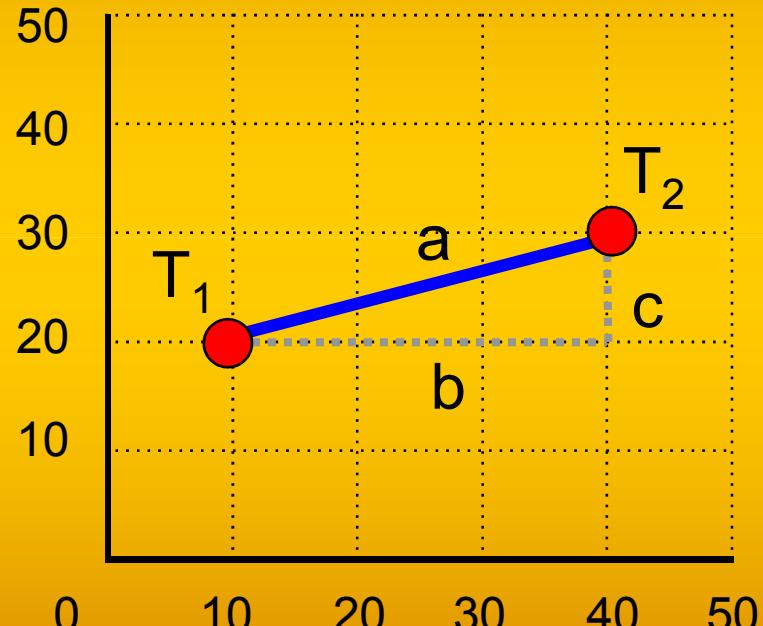
$$= \sqrt{(40-10)^2 + (30-20)^2}$$

$$= \sqrt{(30)^2 + (10)^2}$$

$$= \sqrt{900+100}$$

$$= \sqrt{1000} = 31.628$$

# Penghitungan jarak dengan vector



$$T_1 = \begin{bmatrix} 10 \\ 20 \end{bmatrix} \quad T_2 = \begin{bmatrix} 40 \\ 30 \end{bmatrix}$$

$$T = T_2 - T_1 = \begin{bmatrix} 40 \\ 30 \end{bmatrix} - \begin{bmatrix} 10 \\ 20 \end{bmatrix} = \begin{bmatrix} 30 \\ 10 \end{bmatrix}$$

$$D = T^T \times T$$

$$= [30 \quad 10] \begin{bmatrix} 30 \\ 10 \end{bmatrix} = 900 + 100 = 1000$$

$$a = \sqrt{D} = \sqrt{1000} = 31.628$$