

# Machine Learning

## Cluster Analysis

Ali Ridho Barabbah

Knowledge Engineering Research Group

Soft Computing Laboratory

Department of Information and Computer Engineering

Politeknik Elektronika Negeri Surabaya



Politeknik Elektronika Negeri Surabaya  
Departemen Teknik Informatika dan Komputer

# Konten

- Cluster Analysis
- Variance
- Good Cluster
- Variance Within Cluster
- Variance Between Cluster
- Centroid Proximity Cluster
- Error Ratio

# Tujuan Instruksi Umum

Mahasiswa mampu menyelesaikan masalah – masalah menggunakan metode mesin pembelajaran yang tepat berdasarkan supervised, unsupervised dan reinforcement learning, baik secara individu maupun berkelompok/kerjasama tim.

# Tujuan Instruksi Khusus

- Memahami bagaimana menilai sebuah hasil klasterisasi yang baik
- Mampu menerapkan Klasterisasi dan Analisa Klaster

# Cluster Analysis

- Variance
- Sum of Squared Error
- Centroid Proximity Index
- Error ratio



# Variance

- Digunakan untuk mengukur nilai penyebaran dari data-data hasil clustering
- Dipakai untuk data yang bertipe unsupervised
- Variance pada clustering ada 2 macam:
  - Variance within cluster
  - Variance between clusters



# Good cluster

is when the members of a cluster have a high degree of similarity to each other (internal homogeneity) and are not like members of other clusters (external homogeneity)



# Variance & homogeneity

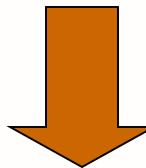
internal homogeneity → Variance within cluster ( $V_w$ )

external homogeneity → Variance between clusters ( $V_b$ )



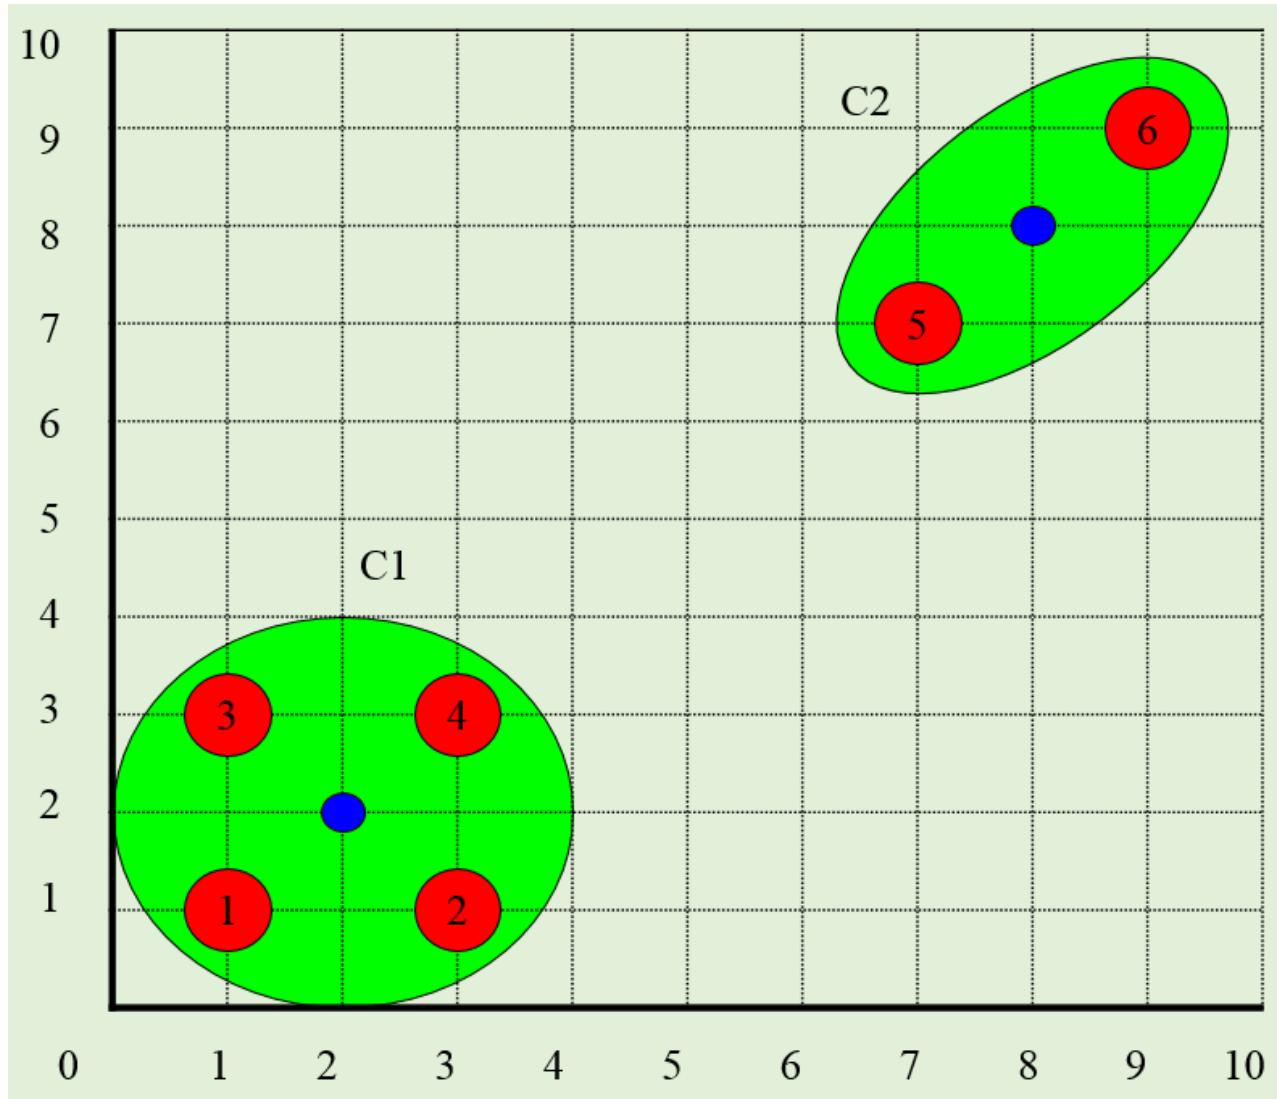
# Ideal cluster

- The ideal cluster has minimum  $V_w$  to express internal homogeneity and maximum  $V_b$  to express external homogeneity.



minimum

$$V = \frac{V_w}{V_b}$$



# Cluster Variance

$$\sigma_c^2 = \frac{1}{n_c - 1} \sum_{i=1}^{n_c} \left( d_i - \bar{d}_i \right)^2$$

$\sigma_c^2$  = variance pada cluster  $c$

$c = 1..k$ , dimana  $k$  = jumlah cluster

$n_c$  = jumlah data pada cluster  $c$

$d_i$  = data ke- $i$  pada suatu cluster

$\bar{d}_i$  = rata-rata dari data pada suatu cluster



# Variance within cluster

$$v_w = \frac{1}{N-k} \sum_{i=1}^k (n_i - 1) \cdot v_i^2$$

$v_w$  = variance within cluster  
 $N$  = jumlah semua data



# Variance between clusters

$$v_b = \frac{1}{k-1} \sum_{i=1}^k n_i (\bar{d}_i - \bar{d})^2$$

$\bar{d}$  = rata-rata dari  $\bar{d}_i$



## Variance dari semua cluster

$$v = \frac{v_w}{v_b}$$



# Sum of Squared Error

- The most widely used criterion to quantify cluster homogeneity is the Sum of Squared Error (SSE) criterion

$$SSE = \frac{\sum_{i=1}^k \sum_{j=1}^{n(s_i)} \|m_{ij} - \bar{s}_i\|^2}{N}$$



# Centriod Proximity Index

- Proposed by Barakbah and Kiyoki<sup>1</sup>
- To analyze the closeness of the final centroids of the clustering result to the centroids of the real data sets.

$$CPI = \min \sum_{i=1}^k (\|c_i - r_i\|)$$

where  $c_i$  is  $i$ -th final centroid of clustering result and  $r_i$  is  $i$ -th real centroid of datasets.

<sup>1</sup>Ali Ridho Barakbah, Yasushi Kiyoki, "A Fast Algorithm for K-Means Optimization using Pillar Algorithm", The 2nd International Workshop with Mentors on Databases, Web and Information Management for Young Researchers, August 2-4, 2010, Tokyo, Japan.

# Error ratio

- Dipakai jika dataset yang digunakan adalah supervised
- Biasanya digunakan untuk mengukur tingkat presisi dari metode clustering
- Rumus:

$$Error = \frac{\text{missclassified}}{\text{jumlahdata}} \times 100\%$$



# Contoh sederhana

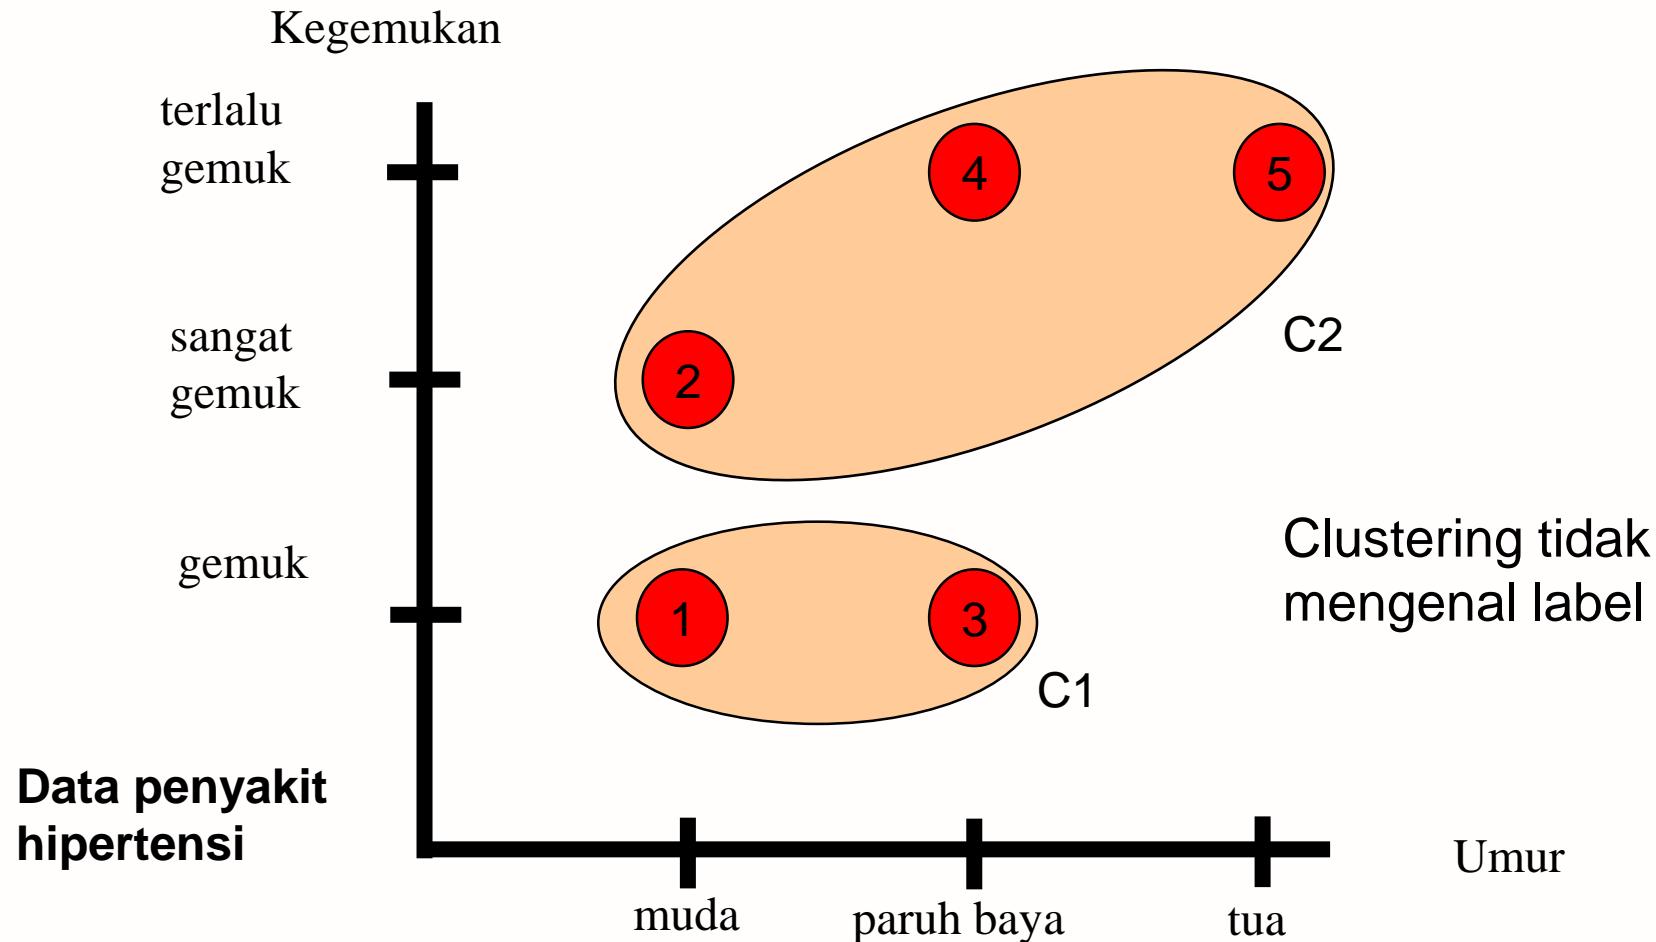
Data penyakit hipertensi

Data ke-	Umur	Kegemukan	Hipertensi
1	muda	gemuk	Tidak
2	muda	sangat gemuk	Tidak
3	paruh baya	gemuk	Tidak
4	paruh baya	terlalu gemuk	Ya
5	tua	terlalu gemuk	Ya

label

Supervised data

# Contoh Hasil Clustering



# Menghitung error ratio

	Label	<u>Kombinasi 1</u> C1 → Tidak C2 → Ya	<u>Kombinasi 2</u> C1 → Ya C2 → Tidak
Data 1	Tidak	Tidak	Ya
Data 2	Tidak	Ya	Tidak
Data 3	Tidak	Tidak	Ya
Data 4	Ya	Ya	Tidak
Data 5	Ya	Ya	Tidak
Misclassified		1	4
Error ratio		20%	80%

Semua kemungkinan label dicoba sehingga ada  $n!$  kombinasi

Ambil error ratio yang terkecil

# Latihan Soal

1. Tambahkan analisa klaster pada implementasi K-means untuk data Ruspini dalam program!
2. Tambahkan analisa klaster pada implementasi Hirarki untuk data Ruspini dalam program!



# Referensi

- Tom Michael, *Machine Learning*, McGraw-Hill publisher, 1997.
- Ali Ridho Barakbah, *Machine Learning*, Lecture Handout, Electronic Engineering Polytechnic Institute of Surabaya.
- UCI Repository, Ruspini Dataset.



**bridge to the future**



<http://www.eepis-its.edu>