

# Instance based learning (Nearest Neighbor)

Ali Ridho Barakbah

# Nearest Neighbor (NN)

- Merupakan suatu method untuk mengklasifikasikan suatu data baru berdasarkan similaritas dengan labeled data
  - Similaritas biasanya memakai metrik jarak
  - Satuan jarak umumnya menggunakan euclidian

# Nama lain dari NN

- lazy algorithm
- memory-based
- instance-based
- exemplar-based
- case-based
- experience-based


# Jenis NN

- 1-NN
  - Pengklasifikasikan dilakukan terhadap 1 labeled data terdekat
- k-NN
  - Pengklasifikasikan dilakukan terhadap k labeled data terdekat
  - $k > 1$

# Algoritma 1-NN

- Hitung jarak antara data baru ke setiap labeled data
- Tentukan 1 labeled data yang mempunyai jarak yang paling minimal
- Klasifikasikan data baru ke dalam labeled data tersebut

# 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



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

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

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

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

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

# Contoh kasus:


Pengenalan untuk menentukan seseorang itu mempunyai hipertensi atau tidak


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

tua	sangat gemuk	?
-----	--------------	---

data  
baru

# Penyelesaian dengan 1-NN







# Algoritma k-NN

- Tentukan  $k$
- Hitung jarak antara data baru ke setiap labeled data
- Tentukan  $k$  labeled data yang mempunyai jarak yang paling minimal
- Klasifikasikan data baru ke dalam labeled data yang mayoritas

# Penyelesaian dengan k-NN (misalnya $k=3$ )





# Keuntungan

- Analytically tractable
- Implementasi sangat sederhana
- Memungkinkan parallel implementation

# Kelemahan

- Butuh memori besar
- Komputasi besar