

Machine Learning  
Teknik Informatika - UNIKOM



# Learning –basic concept

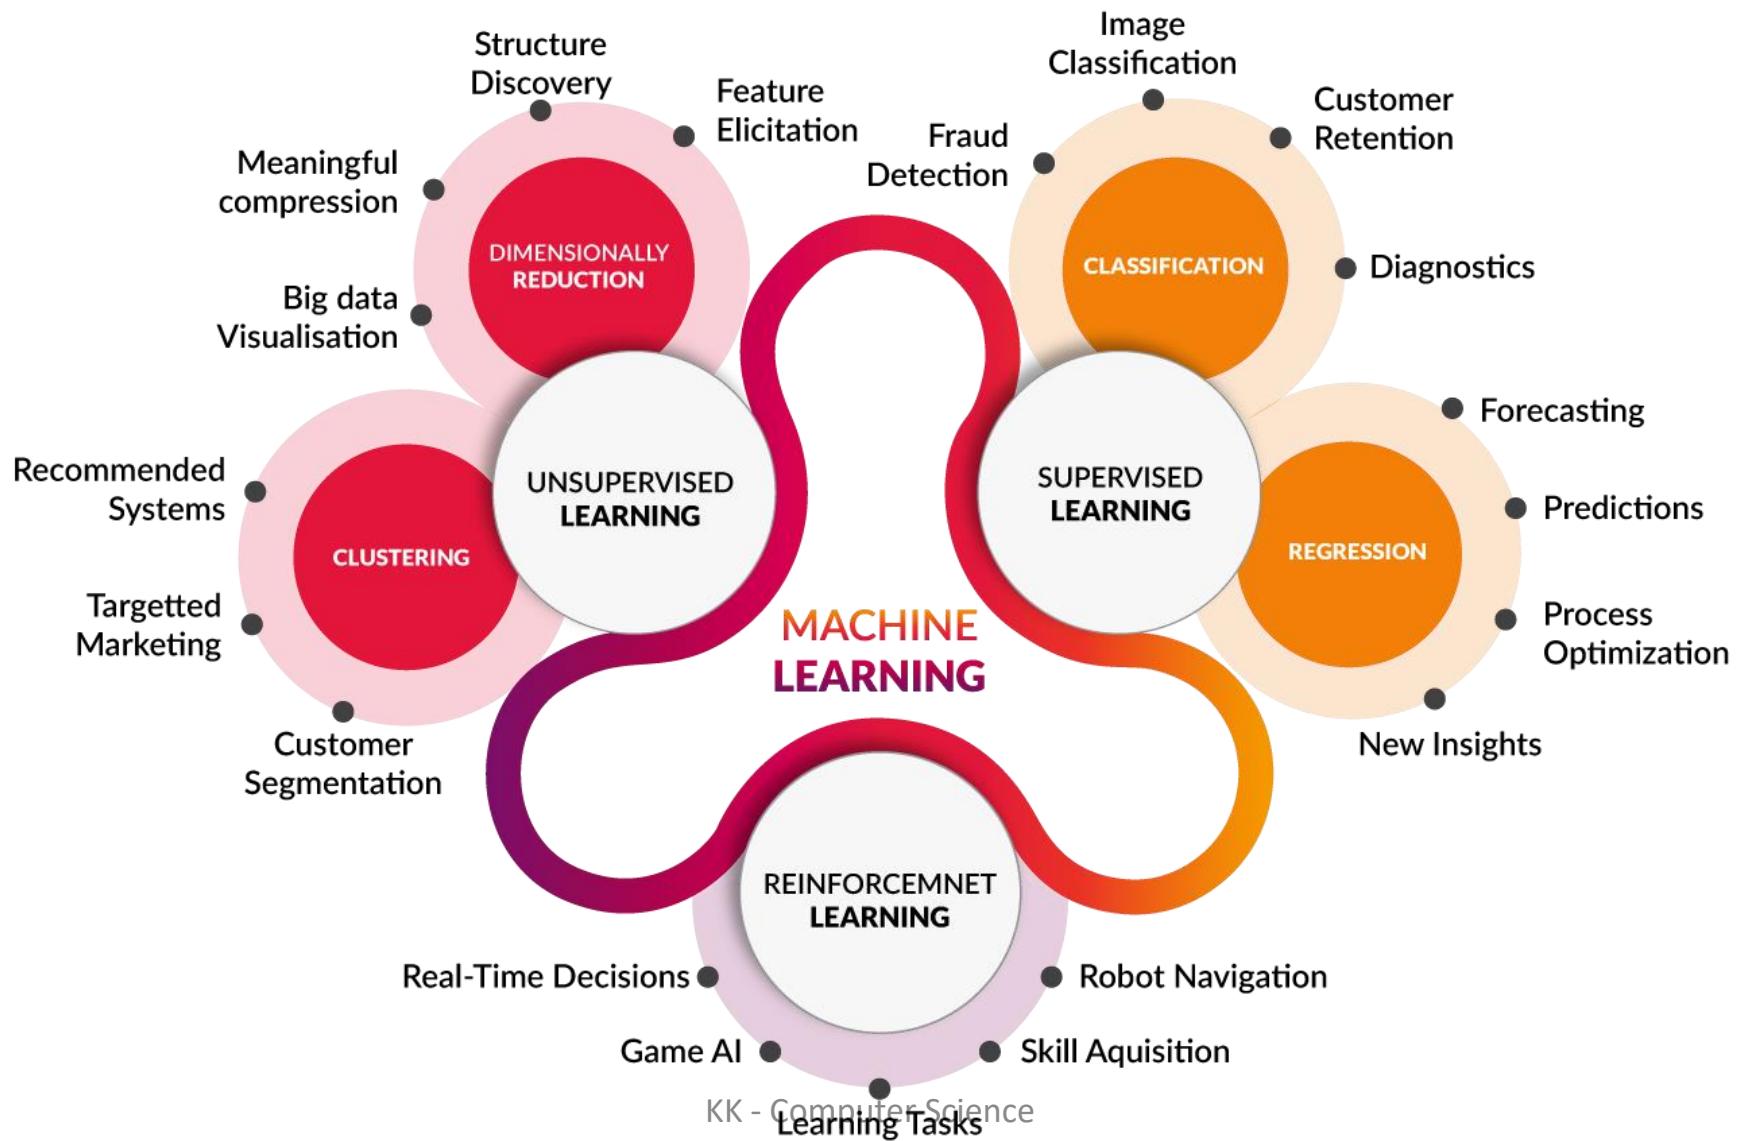
# Learning

- Learning adalah hal penting untuk lingkungan yg tidak diketahui
- Learning berguna untuk metode konstruksi sistem
  - Mendekatkan agen dengan realitas daripada mendeskripsikan lingkungan untuk agen
- Learning memodifikasi mekanisme keputusan agen untuk meningkatkan performa

# Learning objectives

- Persepsi agen seharusnya digunakan bukan hanya untuk beraksi, tapi juga untuk meningkatkan performa di masa datang.
- Tugas-tugas belajar untuk sebuah agen:
  - Kondisi yang ingin dicapai untuk sebuah aksi
  - Perubahan lingkungan yang berpengaruh
  - Nilai untuk setiap kondisi
  - Kondisi yang memiliki nilai tinggi (rendah) → solusi
  - Informasi mana yang relevan
- Learning task – estimations of functions  
 $y=f(x)$ :  $x \rightarrow y$

# Taxonomy of Machine Learning



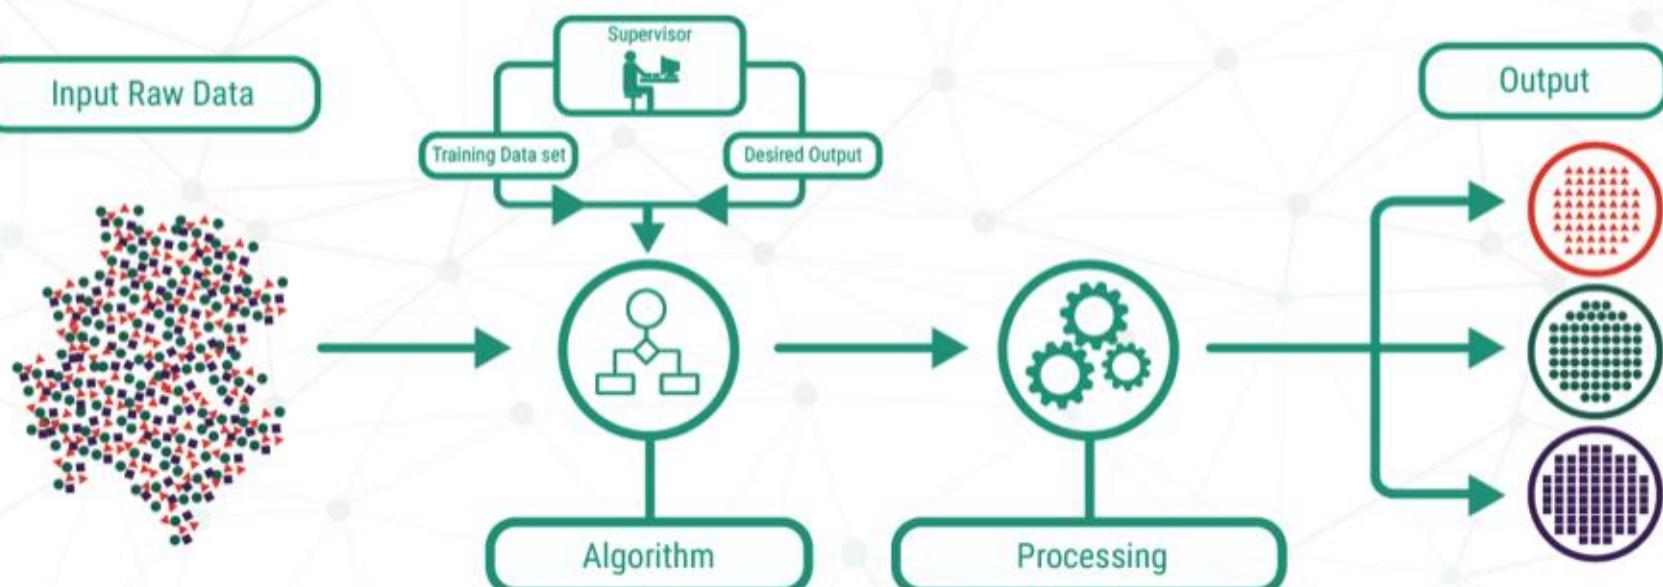
# Supervised Learning

*Supervised learning is the machine learning task of inferring a function from labeled training data*

Mehryar mohri

(foundations of machine learning, 2012, MIT Press)

# SUPERVISED LEARNING



- Supervised learning menggunakan training data yang sudah diberi label untuk mempelajari mapping function, dari input variable ( $x$ ) ke output variable ( $y$ ).

$$y = f(x)$$

- Beberapa algoritma supervised learning
  - Linear regression
  - Logistic regression
  - Multiclass classification
  - Support vector machines

- Classification
  - Classification bertujuan untuk memprediksi outcome dari input yang diberikan , dimana output variable berbentuk kategori-kategori. Misal pria/wanita, sakit/sehat, tinggi/rendah
- Regression
  - Regression bertujuan untuk memprediksi outcome dari input, dimana output variable berbentuk nilai actual (real values), misal tinggi badan seseorang, curah hujan.

# Algoritma Supervised Learning

- Decision tree
- Naïve bayes classifier
- Artificial neural network
- Support vector machine
- Linear regression
- Logistic regression
- CART
- KNN (K- Nearest Neighbor)

# Algoritma kNN (k-Nearest Neighbor)

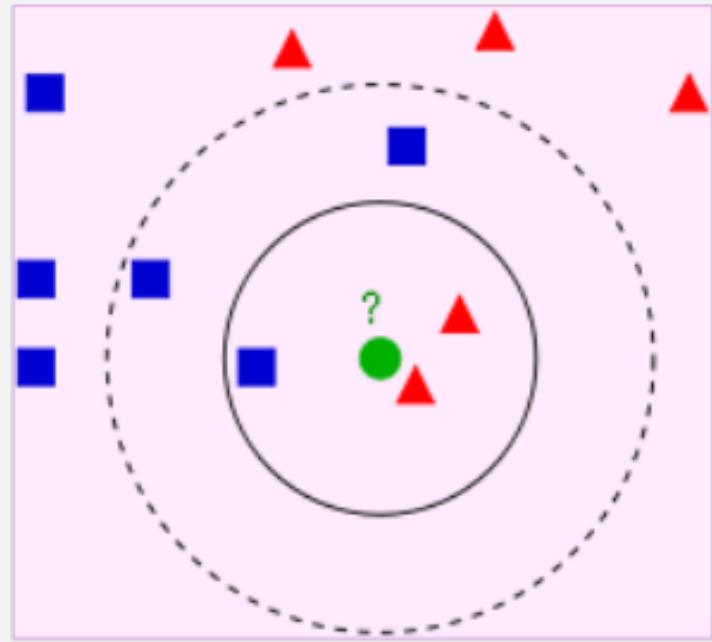
# Deskripsi kNN

- KNN adalah sebuah metode klasifikasi terhadap sekumpulan data berdasarkan pembelajaran data yang sudah terklasifikasikan sebelumnya.
- Termasuk dalam *supervised learning*, dimana hasil *query instance* yang baru diklasifikasikan berdasarkan mayoritas kedekatan jarak dari kategori yang ada dalam KNN.

# Deskripsi kNN

- Diberikan titik query, akan ditemukan sejumlah  $k$  obyek atau (titik training) yang paling dekat dengan titik query.
- Klasifikasi menggunakan voting terbanyak diantara klasifikasi dari  $k$  obyek
- Algoritma  $k$ -nearest neighbor (KNN) menggunakan klasifikasi ketetanggaan sebagai nilai prediksi dari query instance yang baru.

- Jika  $k=3$  maka lingkaran hijau akan masuk dalam kategori segitiga merah
- Jika  $k=5$  maka lingkaran hijau akan masuk dalam kategori segiempat biru.



# Ukuran Jarak

- Dekat atau jauhnya tetangga biasanya dihitung berdasarkan *Euclidean Distance*.

$$D(a, b) = \sqrt{\sum_{k=1}^d (a_k - b_k)^2},$$

- Dimana  $D(a,b)$  adalah jarak skalar dari dua buah vektor data  $a$  dan  $b$  yang berupa matrik berukuran  $d$  dimensi.

# Beberapa macam jarak yang dapat digunakan

- Jarak Euclidean

$$d(x, y) = \|x - y\| = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

- Jarak Manhattan atau Cityblock

$$d(x, y) = \sum_{i=1}^n |x_i - y_i|$$

- Jarak Minkowski

$$d(x, y) = \|x - y\|_q = \left( \sum |x - y|^q \right)^{\frac{1}{q}}$$

- Jarak Mahalanobis

$$d(\vec{x}, \vec{y}) = \sqrt{(\vec{x} - \vec{y})^T S^{-1} (\vec{x} - \vec{y})}$$

# Kelebihan

Kelebihan KNN:

- Simpel
- Efektif jika data besar
- Intuitif
- Performa cukup baik
- Tahan terhadap data latih yang noisy

# Kekurangan

## Kekurangan KNN :

- Waktu komputasi tinggi jika data latih besar. Disebabkan oleh semua data diukur jaraknya untuk setiap data uji.
- Sangat sensitive dengan ciri yang redundant atau tidak relevan. Ditanggulangi dengan seleksi ciri atau pembobotan ciri.
- Tidak diketahui perhitungan jarak apa yang paling sesuai untuk dataset tertentu.

# Algoritma

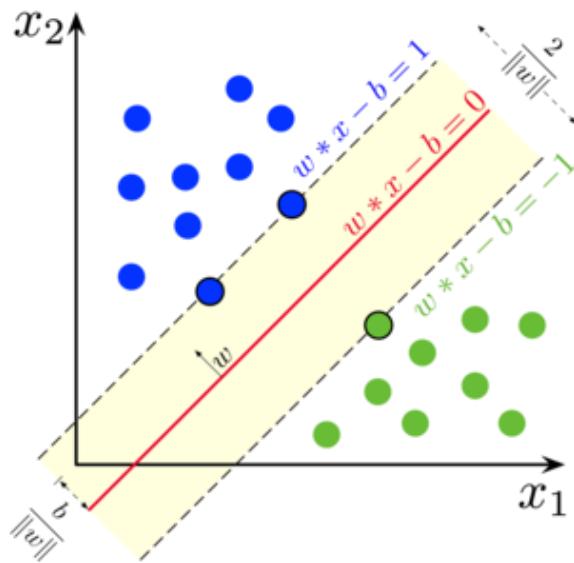
1. Menentukan parameter k (jumlah tetangga paling dekat).
2. Menghitung kuadrat jarak eucliden objek terhadap data training yang diberikan.
3. Mengurutkan hasil no 2 secara ascending
4. Mengumpulkan kategori Y (Klasifikasi nearest neighbor berdasarkan nilai k)
5. Dengan menggunakan kategori nearest neighbor yang paling mayoritas maka dapat diprediskan kategori objek .

# Support Vector Machine

# Kenapa SVM?

- SVM dapat menemukan solusi optimum global
- Dalam setiap kasus, memiliki solusi yang hampir selalu sama.

# Support Vector Classifier



[https://upload.wikimedia.org/wikipedia/commons/thumb/7/72/SVM\\_margin.png/300px-SVM\\_margin.png](https://upload.wikimedia.org/wikipedia/commons/thumb/7/72/SVM_margin.png/300px-SVM_margin.png)

# Inti dari SVC

- mencari hyperplane yang terbaik
- memaksimalkan margin
- Penentuan suatu data termasuk kelas yang mana dengan cara

$$f(\bar{x}_i) = \text{sgn}(w^T \bar{x}_i + b)$$

# Pelatihan

Untuk menemukan  $\alpha_1, \alpha_2, \dots, \alpha_n$

$$\max_{\alpha} L(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j x_i^T x_j$$

Dengan syarat:

1.  $\sum_{i=1}^n \alpha_i y_i = 0$
2.  $\alpha_i \geq 0$ , untuk setiap  $\alpha_i$

$w = \sum \alpha_i y_i \bar{x}_i$  dan  $b = y_k - \bar{w}^T \bar{x}_k$  untuk setiap  $\bar{x}_k$  sedemikian hingga  $\alpha_k \neq 0$

Untuk setiap  $\alpha_i$  yang tidak nol, mengidentifikasi  $\bar{x}$  adalah support vector.

# Pengujian SVC

$$f(\bar{x}) = \sum \alpha_i y_i \bar{x}_i^T \bar{x} + b$$

Jika  $f(\bar{x}) > 0$  maka kelas akan sama dengan +1

Jika  $f(\bar{x}) < 0$  maka kelas akan sama dengan -1

# Sequential Minimal Optimization

- Pilih  $\alpha_i$  dan  $\alpha_j$
- Tentukan nilai L dan H sehingga  $L \leq \alpha_j \leq H$
- $$L = \begin{cases} \max(0, \alpha_j - \alpha_i) & \text{jika } y_i = y_j \\ \max(0, \alpha_i + \alpha_j - C) & \text{jika } y_i \neq y_j \end{cases}$$
- $$H = \begin{cases} \min(C, C + \alpha_j - \alpha_i) & \text{jika } y_i = y_j \\ \min(C, \alpha_i + \alpha_j) & \text{jika } y_i \neq y_j \end{cases}$$
- [www.stanford.edu/class/cs229/materials/smo.pdf](http://www.stanford.edu/class/cs229/materials/smo.pdf)

# SMO 2

- Update  $\alpha_j$  jika  $\alpha_j$  tidak terletak antara L dan H

$$\alpha_j = \alpha_j - \frac{y^{(j)}(E_i - E_j)}{\eta}$$

Dimana

$$E_k = f(x^{(k)}) - y^{(k)}$$
$$\eta = 2\langle x^{(i)}, x^{(j)} \rangle - \langle x^{(i)}, x^{(i)} \rangle - \langle x^{(j)}, x^{(j)} \rangle$$

$$f(x^{(k)}) = \sum_{i=1}^m \alpha_i y_i x^{(i)} x^{(k)} + b$$

Untuk menghitung  $\langle x^{(i)}, x^{(j)} \rangle$  bisa menggunakan fungsi kernel

# SMO 3

- Update  $\alpha_j$  jika  $\alpha_j$  terletak antara L dan H

$$\alpha_j = \begin{cases} H & , \text{jika } \alpha_j > H \\ \alpha_j & , \text{jika } L \leq \alpha_j \leq H \\ L & , \text{jika } \alpha_j < L \end{cases}$$

# SMO 4

- Update  $\alpha_i$

$$\alpha_i = \alpha_i + y^{(i)}y^{(j)} \left( \alpha_j^{(old)} - \alpha_j \right)$$

# SMO b

- Setelah  $\alpha_i$  dan  $\alpha_j$  diupdate maka hitung

$$b_1 = b - E_i - y^{(i)} \left( \alpha_i - \alpha_i^{(old)} \right) \langle x^{(i)}, x^{(i)} \rangle - y^{(j)} \left( \alpha_j - \alpha_j^{(old)} \right) \langle x^{(i)}, x^{(j)} \rangle$$

Dan

$$b_2 = b - E_j - y^{(i)} \left( \alpha_i - \alpha_i^{(old)} \right) \langle x^{(i)}, x^{(j)} \rangle - y^{(j)} \left( \alpha_j - \alpha_j^{(old)} \right) \langle x^{(j)}, x^{(j)} \rangle$$

Maka b diupdate dengan cara

$$b = \begin{cases} b_1 & , jika 0 < \alpha_i < C \\ b_2 & , jika 0 < \alpha_j < C \\ \frac{b_1 + b_2}{2} & lainnya \end{cases}$$

- Input:  $C$ ,  $\text{tol}$ ,  $\text{max\_passes}$ , data training  $\{(x^{(1)}, y^{(1)}), (x^{(2)}, y^{(2)}), \dots, (x^{(m)}, y^{(m)})\}$
- Output:  $\alpha \in R^m$  dan  $b \in R$
- Inisialisasi  $\alpha_i = 0, \forall i$  dan  $b = 0$
- Inisialisasi  $passes = 0$
- Selama ( $passes < maxpasses$ )
- Num\_changed\_alpha=0
- Untuk  $i = 1..0$
- Hitung  $E_i = f(x^{(i)}) - y^{(i)}$

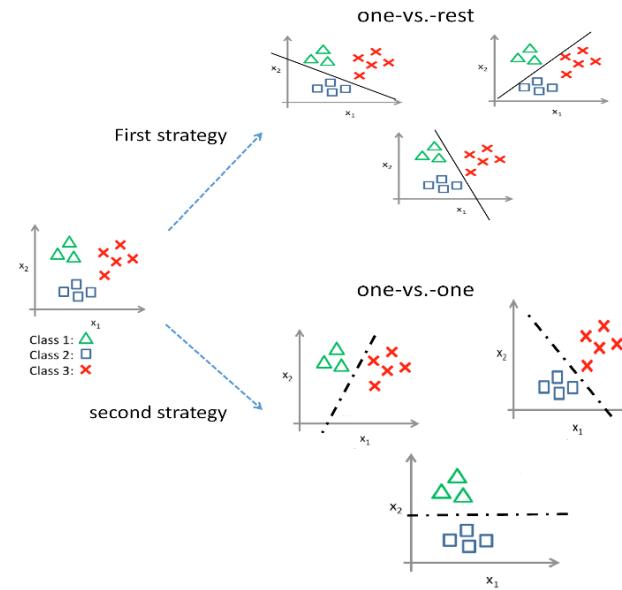
- Jika  $y^{(i)}E_i < -tol \ \&\& \alpha_i < C$  atau  $y^{(i)}E_i > tol \ \&\& \alpha_i > 0$
- Pilih  $j \neq i$  secara random
- Hitung  $E_j = f(x^{(j)}) - y^{(j)}$
- $\alpha_i^{(old)} = \alpha_i$  dan  $\alpha_j^{(old)} = \alpha_j$
- Hitung L dan H
- Jika  $L=H$  maka  $i=i+1$
- Hitung  $\eta$
- Jika  $\eta \geq 0$  lanjut  $i = i + 1$

- Hitung  $\alpha_j$
- Jika  $|\alpha_j - \alpha_j^{(old)}| < 10^{-5}$
- i=i+1
- Hitung  $\alpha_i$
- Hitung  $b_1$  dan  $b_2$
- Hitung b
- Num\_changed\_alphas = num\_changed\_alpha+1
- End if
- End for
- Jika num\_changed = 0
- Passes = passes +1
- Else
- Passes = 0
- End while

# MULTICLASS

- SVC hanya dapat mengklasifikasikan untuk 2 kelas, tetapi dapat dimodifikasi, yaitu multiclass SVM

1. One against All
2. One against One



[https://www.researchgate.net/profile/Shervan\\_Fekri\\_Ershad2/publication/332370066/figure/fig22/AS:746765703720962@155505426099/Sample-example-of-a-multiclass-support-vector-machine-The-SVM-algorithms-applied-to-a.ppm](https://www.researchgate.net/profile/Shervan_Fekri_Ershad2/publication/332370066/figure/fig22/AS:746765703720962@155505426099/Sample-example-of-a-multiclass-support-vector-machine-The-SVM-algorithms-applied-to-a.ppm)

# Perbandingan

## One Against All

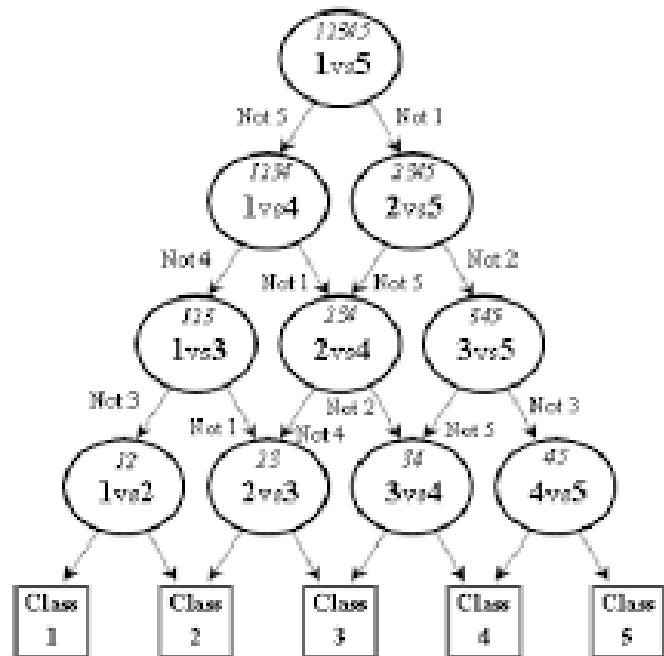
- Banyak hyperplane yang harus dibanyak sebanyak kelas yang akan diklasifikasi
- Kerugian terlalu banyak daerah yang tidak terdefinisi
- Penentuan kelas dengan cara maksimum nilai  $f(\bar{x})$

## One Against One

- Banyak hyperplane yang harus dibangun sebanyak  $\frac{k(k+1)}{2}$
- Daerah yang tidak terdefinisi hanya sedikit
- Penentuan kelas dengan cara voting

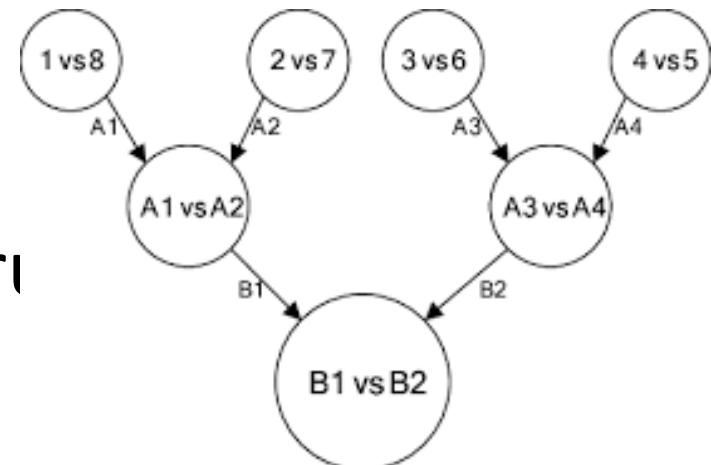
# Decesion Directed Acyclic Graph

- Jumlah hyperplane yang digunakan sebanyak one against one
- Penentuan kelas menggunakan system gugur

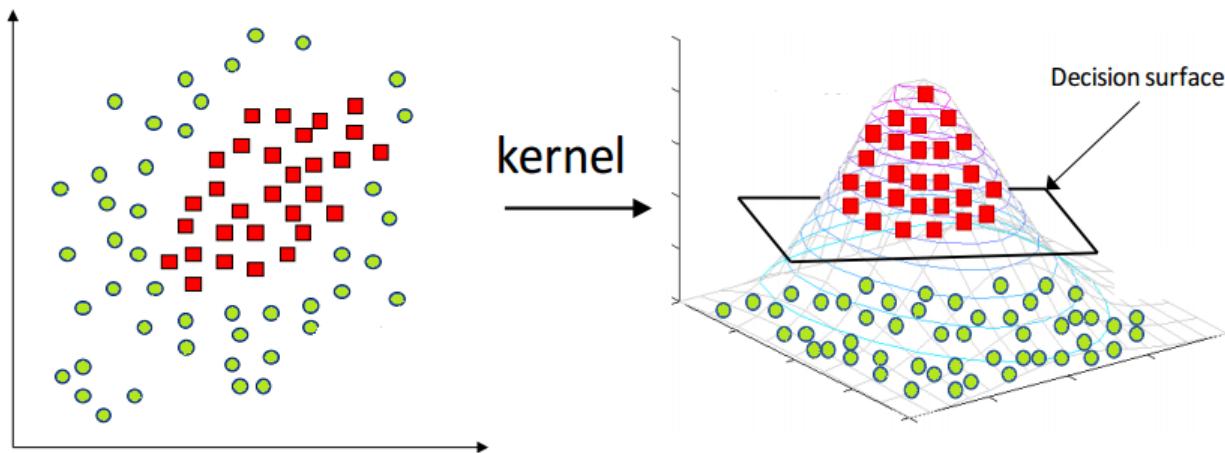


# Adaptive Directed Acyclic Graph

- Perbaikan dari DDAG, dengan cara membalikkan grafik, misal ada 8 kelas yang akan diklasifikasi maka diawal akan ada 4 klasifikasi
- Kelas yang terpilih telah
- Lebih tahan terhadap uru



# Kernel



[https://miro.medium.com/max/1676/0\\*5AtpuJ7X08V4zc9f.png](https://miro.medium.com/max/1676/0*5AtpuJ7X08V4zc9f.png)

# Jenis-jenis Kernel

1. Kernel Linier,  $K(x, x_k) = x_k^T x$
2. Kernel Polynomial,  $K(x, x_k) = (x_k^T x + 1)^d$
3. Kernel Gaussian (radial basis function, RBF),  
$$K(x, x_k) = \exp\left(\frac{-\|x-x_k\|^2}{\sigma^2}\right)$$
4. Kernel sigmoid,  $K(x, x_k) = \tanh(\kappa x_k^T x + \theta)$

Dimana  $\tanh(\alpha) = \frac{e^{2\alpha}-1}{e^{2\alpha}+1}$