

ÖRÜNTÜ TANIMA

Pattern Recognition


Yapay Sinir Ağlarında sık kullanılan uygulamalar.

- Yazı Tanıma
- Görüntü Tanıma
- Konuşma Tanıma
- Biyolojik işaretlerin tanınması
↳ EMG, EEG, EOG, ECG.....
↓
hareket
sınıflandırma (classification)

Örüntü tanımanın temel amacı \Rightarrow SINIFLANDIRMA

Örüntü tanımanın adımları

1. Faz : Özellik çıkarma
(Feature extraction)
2. Faz : Sınıflandırma (classification)



Özellik Vektörleri ve Özellik Uzayı (Feature Vectors) (Feature Space)

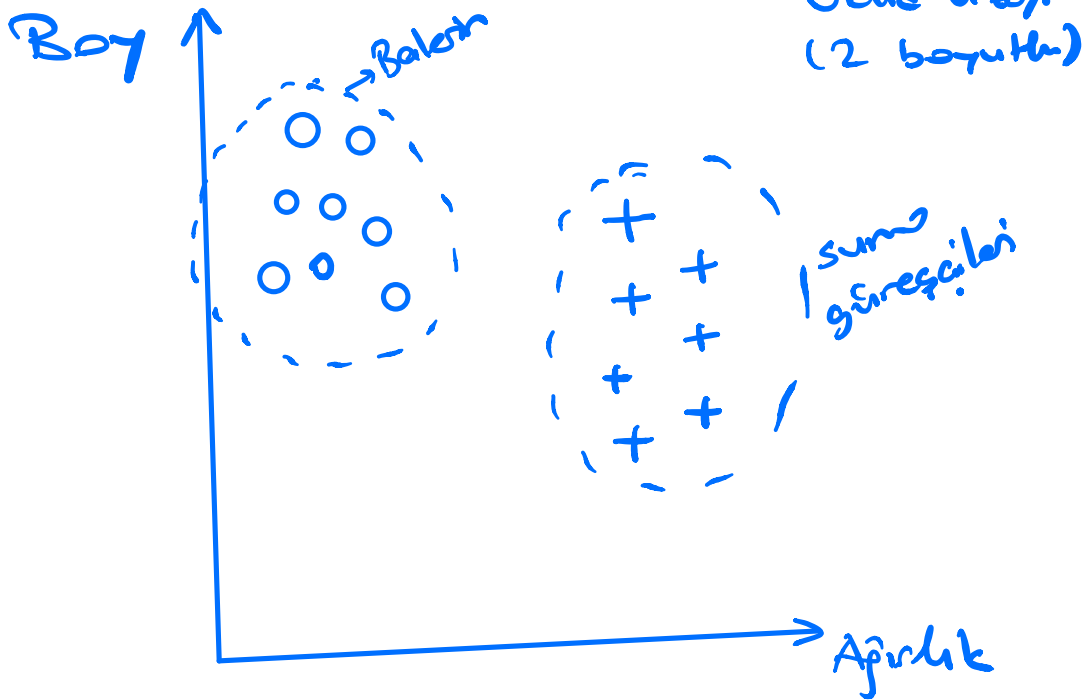
↓
n adet girdiden
oluşan bir küme

vektörün boyutu

n boyutlu
bir uzay
oluşacaktır.

Örnek: Balerin X Sumo Güreşçileri

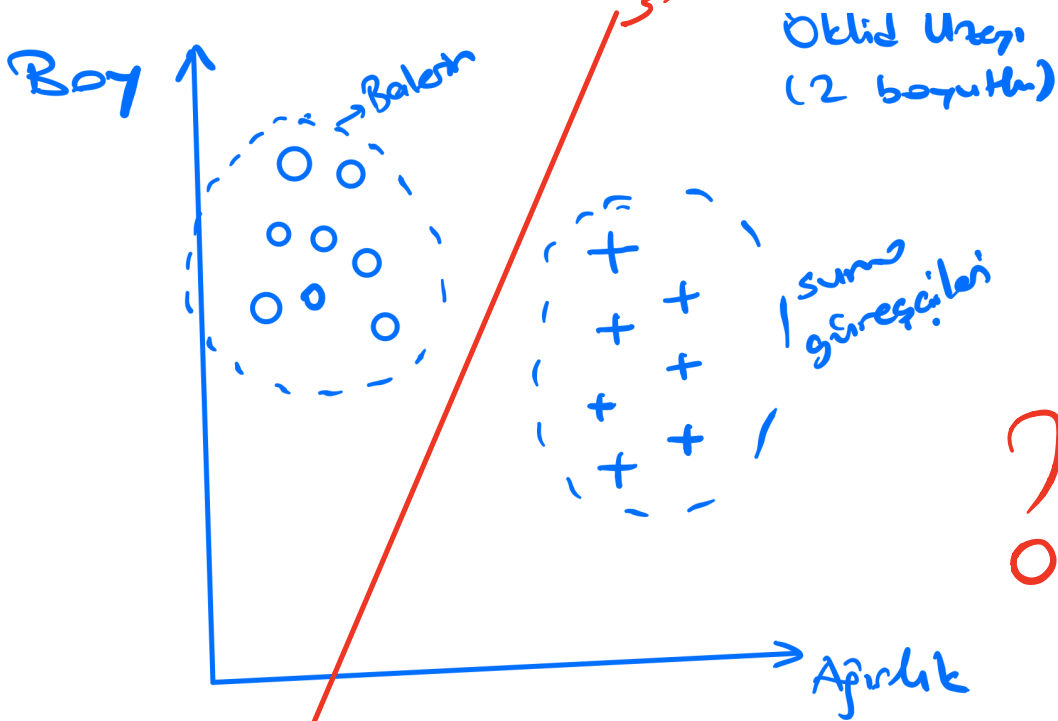
boy ve ağırlık ⇒ özellikler



Kişi	Ağırlık	Boy	
1	1	1	S
2	1	1	B
3	1	1	
4	1	1	
5	1	1	

Ayırma fonksiyonu:

Discriminant function

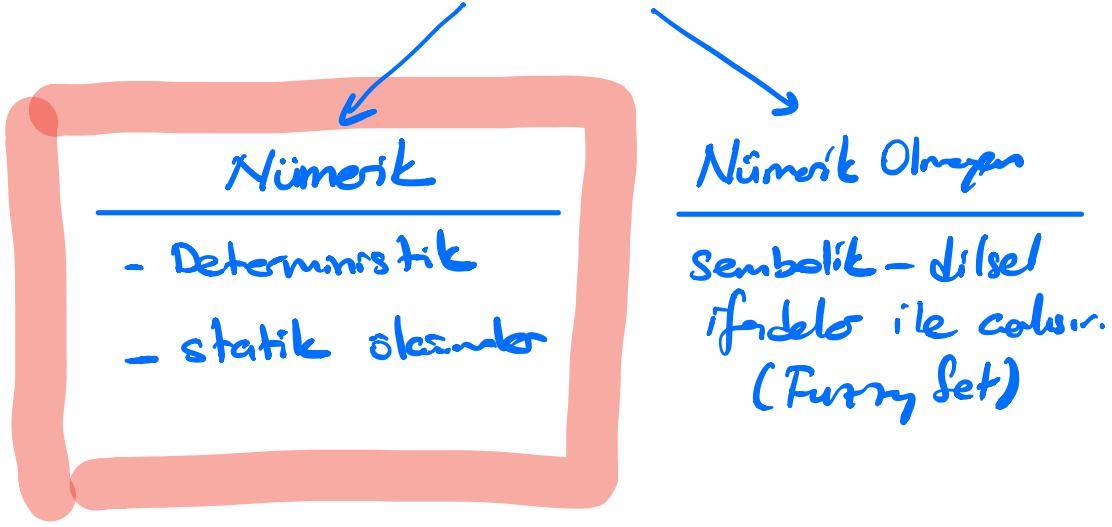


Linear sınıflandıran karar sınırı

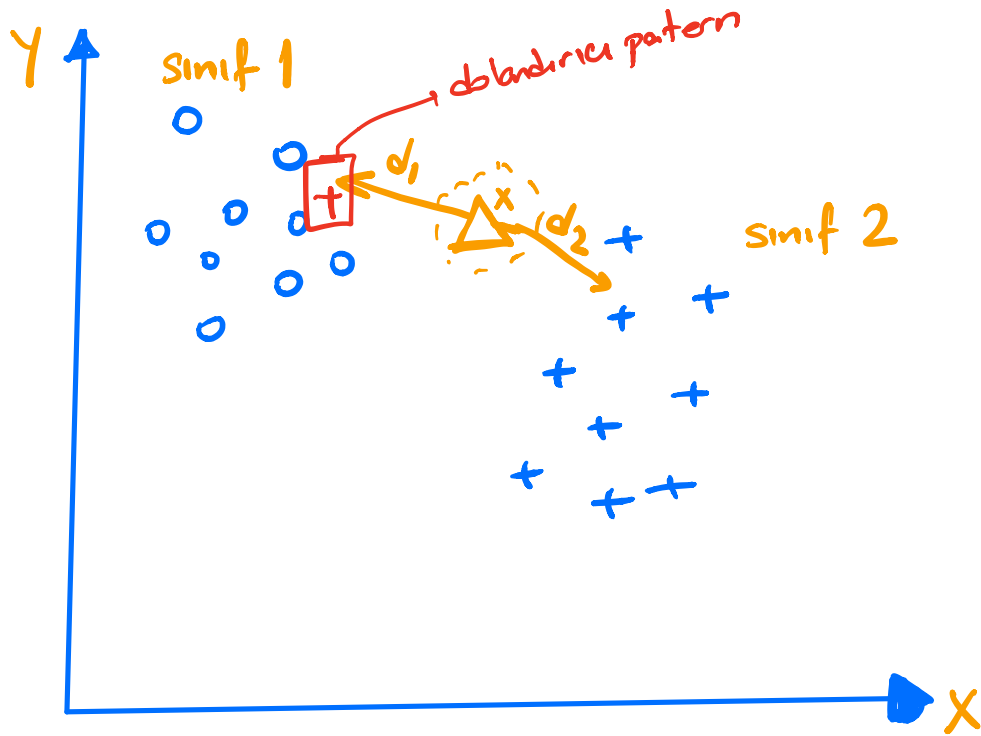
?

o

SINIFLANDIRMA TEKNİKLERİ



En Yakın Komşuluk Sınıflandırması: (Nearest Neighbour Classification)



Δ^x sınıflandırılmamış örneği

d_1 : sınıf 1'e en yakın uzaklığı

d_2 : sınıf 2'ye en yakın uzaklık

$f(x) \rightarrow$ ayırtetme fonksiyonu

$f(x) = \text{en yakın(sınıf 1)} - \text{en yakın(sınıf 2)}$

Uzaklık metrikleri :

1) Hamming uzaklık örneği :

$$X = (x_1, x_2, \dots)$$

$$Y = (y_1, y_2, \dots)$$

$$H = \sum (|x_i - y_i|)$$

Genellikle ikili (binary) vektör karşılaştırmasında kullanılır.

$$|x_i - y_i| \equiv x_i \oplus y_i$$

\oplus : EXOR işlemi

x	y	z
0	0	0
0	1	1
1	0	1
1	1	0

Örnek: $x = (1101 \ 1001)$

$y = (1001 \ 1101)$

Hamming mesafesi (uzaklığını bulunuz)

$$x \oplus y = (1101 \ 1001) \oplus (1001 \ 1101)$$

$$= 0100 \ 0100$$

$$d(x, y) = 2$$

Örnek: $x = 010$ $z = 101$
 $y = 011$ $w = 111$

Minimum (en küçük) Hamming uzaklığını bulun.

$$010 \oplus 011, d(010^x, 011^y) = 1$$

$$010 \oplus 101, d(x, z) = 3$$

$$010 \oplus 111, d(x, w) = 2$$

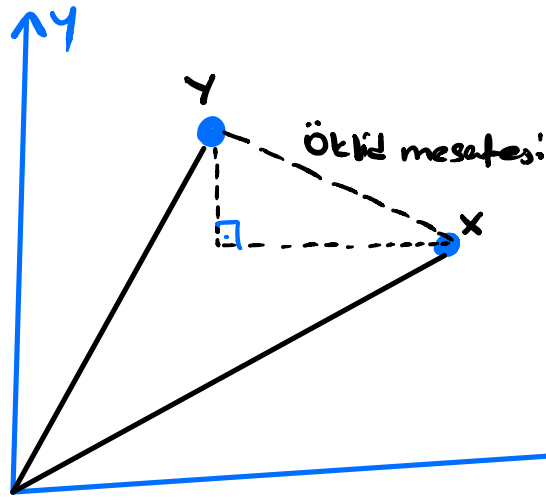
$$011 \oplus 101, d(y, z) = 2$$

$$011 \oplus 111, d(y, w) = 1$$

$$101 \oplus 111, d(z, w) = 1$$

$$d_{\min} = \underline{\underline{1}}$$

Euclidean (Öklid) uzaklık ölçümü:



$$d(X, Y)_{\text{ökl}} = \sqrt{\left(\sum_{i=1}^n (X_i - Y_i)^2 \right)}$$


n: vektör boyutu

Eğer $n=2$ ise

$$d(X, Y)_{\text{ökl}} = \sqrt{\underset{\downarrow}{(x_1 - y_1)}^2 + \underset{\downarrow}{(x_2 - y_2)}^2}$$

Örnek:

	Par 1	Par 2
1. Kişi	20	80
2. Kişi	30	44
3. Kişi	90	40



$$K1 \div K2$$

$$d = \sqrt{(20-30)^2 + (80-44)^2} = 37.36$$

$$K1 \div K3$$

$$d = \sqrt{(20-90)^2 + (80-40)^2} = 80.62$$

$$K_2 \div K_3$$

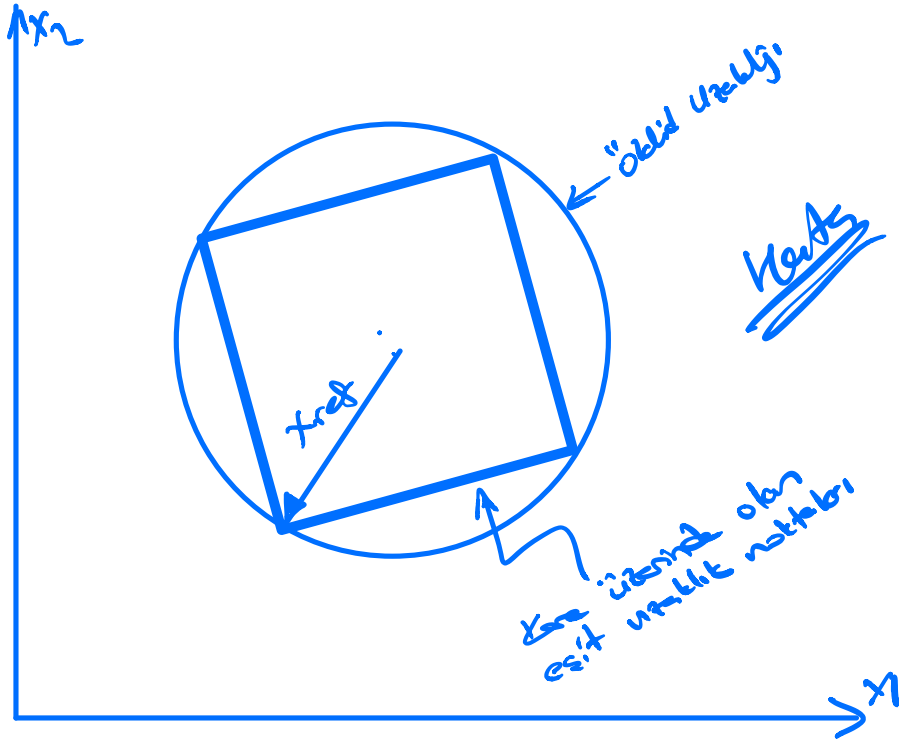
$$d = \sqrt{(30-90)^2 + (44-40)^2} = 60.13$$

Manhattan Uzaklığı:


Öklid uzaklığın basitleştirilmiş versiyonu.

$$D = \sum_n |x_j - y_j|$$

Öklidden daha hızlı sonuç verir.



Karesel uzaklık:





$$D = \max |x_i - y_i|$$

Not: Manhattan metodunda ortaya çıkan karelerden daha büyük bir kare meydana gelir.

LINEER SINIFLANDIRICILAR

Linear (değişel)



Ağırlık vektörünün yönelimi (orientation)

Linear Karar Sınırlarını tanımlar.

$$f(x) = \sum_{i=1}^n w_i x_i \Rightarrow \text{c. kus. fonksyon}$$

x_i : bir giriş vektörünün i . komponenti

w_i : bir ağırlık vektörünün i . komponenti

n : Giriş vektör boyutu

Sınıf tanımlaması:

Eğer $f(x) > 0 \Rightarrow$ sınıf 1

Eğer $f(x) < 0 \Rightarrow$ sınıf 2

Matris cebiriyle uygun olarak $f(x)$ 'i
yeniden tanımlayalım:

$$f(x) = \sum w_i x_i - \theta$$

$$f(x) = (|w| |x| \cos \phi - \theta)$$

ϕ : w ile x vektörleri arasındaki açı

$$f(a) = \sum w_i x_i - \theta = 0$$

$$x_1 \times w_1 + x_2 \times w_2 - \theta = 0$$

$$x_2 = -\frac{w_1}{w_2} \cdot x_1 + \frac{\theta}{w_2}$$

$$y = m x + c \rightarrow \text{bir fonk. lineer}$$

Eğer $m = w_1, w_2$ tarafından kontrol edilir.