

# Pattern Classification

All materials in these slides were taken from  
*Pattern Classification (2nd ed)* by R. O.  
Duda, P. E. Hart and D. G. Stork, John Wiley  
& Sons, 2000  
with the permission of the authors and the  
publisher

# Capitulo 4 (parte 2): Clasificación no paramétrica (Secciones 4.3-4.5)


Parzen Window

$K_n$  –Nearest Neighbor Estimation

The Nearest-Neighbor Rule


# Probabilistic Neural Networks

- Los vectores a clasificar (ingreso) están conectados con  $n$  patrones, con pesos  $w$  estimados con la muestra de entrenamiento.
- Los patrones están conectados con las  $c$  clases, también de acuerdo a la muestra de entrenamiento



# • Algoritmo de entrenamiento

1. Normalizar cada muestra de entrenamiento,  $\| \mathbf{x}_i \| = 1$
2. Poner la primera muestra de entrenamiento  $\mathbf{x}_1$  en las unidades de entrada
3. Definir los pesos de los enlaces de la muestra  $\mathbf{x}_1$  con el primer patron como  $w_{1k} = x_{1k}$  con  $k=1, \dots, d$ .
4. Hacer un enlace desde el patron 1 a la clase conocida de la muestra :  $\mathbf{x}_1 \in \omega_j$  entonces  $p_1 \rightarrow \omega_j$
5. Repetir el proceso para todos los patrones de entrenamiento



**FIGURE 4.9.** A probabilistic neural network (PNN) consists of  $d$  input units,  $n$  pattern units, and  $c$  category units.

Cada unidad patron tiene como vector de pesos a una muestra de entrenamiento. La etiqueta de dicha muestra produce un enlace con las unidades de categoria.

# Algoritmo de clasificacion

- Normalizar el vector  $x$  a clasificar y ponerlo en la unidad de entrada
- Cada patron calcula el producto interno con sus pesos para armar la red de activacion

$$net_k = w_k^t \cdot x$$


$$f(net_k) = \exp\left[\frac{net_k - 1}{\sigma^2}\right] \propto \varphi\left(\frac{x - w_k}{h_n}\right)$$

y emite una funcion no lineal hacia la categoria  $\omega_j$  donde esta conectada

- Cada categoria suma las contribuciones de todos los patrones conectados con ella

$$P_n(x | \omega_j) = \sum_{i \rightarrow j} \varphi_i \propto P(\omega_j | x)$$

- Clasifica seleccionando el maximo valor de  $P_n(x | \omega_j)$



**FIGURE 4.9.** A probabilistic neural network (PNN) consists of  $d$  input units,  $n$  pattern units, and  $c$  category units. Each pattern unit forms the inner product of its weight vector and the normalized pattern vector  $\mathbf{x}$  to form  $z = \mathbf{w}^t \mathbf{x}$ , and then it emits  $\exp[(z - 1)/\sigma^2]$ . Each category unit sums such contributions from the pattern unit connected to it. This ensures that the activity in each of the category units represents the Parzen-window density estimate using a circularly symmetric Gaussian window of covariance  $\sigma^2 \mathbf{I}$ , where  $\mathbf{I}$  is the  $d \times d$  identity matrix. From: Richard O. Duda, Peter E. Hart, and David G. Stork, *Pattern Classification*. Copyright © 2001 by John Wiley & Sons, Inc.

- $K_n$  – estimacion de vecinos mas cercanos
  - Objetivo: solucionar el problema de la mejor funcion de ventana
    - Dejemos que el volumen sea una funcion de los datos de entrenamiento
    - Centremos una celda en  $x$  y dejemos crecer el volumen hasta capturar  $k_n$  muestras ( $k_n = f(n)$ )
    - $k_n$  son llamados  $k_n$  vecinos mas cercanos  $x$



Pueden ocurrir dos cosas:

- Densidad es alta cerca de  $x$ ; por lo tanto la celda puede ser pequeña lo cual da una buen resolucion.
- Densidad es pequeña; por lo tanto la celda y se detendra cuando encuentre una region de alta densidad.



Podemos obtener una familia de estimadores poniendo  $k_n = k_1 / \sqrt{n}$  y eligiendo diferentes valores de  $k_1$




$n=1$   
 $k_n=1$



$n=16$   
 $k_n=4$





**FIGURE 4.12.** Several  $k$ -nearest-neighbor estimates of two unidimensional densities: a Gaussian and a bimodal distribution. Notice how the finite  $n$  estimates can be quite "spiky." From: Richard O. Duda, Peter E. Hart, and David G. Stork, *Pattern Classification*. Copyright © 2001 by John Wiley & Sons, Inc.

- Estimation de las probabilidades a posteriori
  - **Objetivo:** estimar  $P(\omega_i | x)$  de un conjunto de  $n$  muestras etiquetadas
    - Pongamos un volumen  $V$  alrededor de  $x$  y capturemos  $k$  muestras
    - $k_i$  muestras alrededor  $k$  resultaron de la clase  $\omega_i$  entonces:

$$p_n(x, \omega_i) = k_i / n \cdot V$$

Un estimador de  $p_n(\omega_i | x)$  es:

$$p_n(\omega_i | x) = \frac{p_n(x, \omega_i)}{\sum_{j=1}^{j=c} p_n(x, \omega_j)} = \frac{k_i}{k}$$

- $k_j/k$  es la fracción de las muestras dentro de la celda que están etiquetadas con  $\omega_j$
- Para una tasa de error mínima, la categoría con más frecuencia de representación dentro de la celda es seleccionada
- Si  $k$  es grande y la celda es suficientemente chica, el desempeño se acercará al mejor posible.

- La regla del vecino mas cercano

- Sea  $D_n = \{x_1, x_2, \dots, x_n\}$  un conjunto de  $n$  patrones etiquetados
- Sea  $x' \in D_n$  el patron mas cercano al punto de test  $x$  entonces la regla del vecino mas cercano para clasificar  $x$  es asignar la etiqueta asociada con  $x'$
- La regla del vecino mas cercano lleva a un error mayor que el minimo posible, la tasa de Bayes.
- Si el numero de patrones es largo (ilimitado), el error del clasificador de vecinos mas cercano no es nunca peor que dos veces la tasa de Bayes
- Si  $n \rightarrow \infty$ , siempre es posible encontrar  $x'$  suficientemente cerca de  $x$  tal que:

$$P(\omega_j | x') \cong P(\omega_j | x)$$


## Ejemplo:

$$x = (0.68, 0.60)^t$$

Patrones	Etiquetas	Probabilidades a posteriori estimadas
$(0.50, 0.30)$	$\omega_2$	$0.25$
	$\omega_3$	$0.75 = P(\omega_m   x)$
$(0.70, 0.65)$	$\omega_5$	$0.70$
	$\omega_6$	$0.30$

Decision:  $\omega_5$  es la etiqueta asignada a  $x$


Si  $P(\omega_m | x) \cong 1$ , entonces la regla del vecino mas cercano es casi siempre la eleccion de Bayes



**FIGURE 4.13.** In two dimensions, the nearest-neighbor algorithm leads to a partitioning of the input space into Voronoi cells, each labeled by the category of the training point it contains. In three dimensions, the cells are three-dimensional, and the decision boundary resembles the surface of a crystal. From: Richard O. Duda, Peter E. Hart, and David G. Stork, *Pattern Classification*. Copyright © 2001 by John Wiley & Sons, Inc.

- La regla de  $k$ -vecinos mas cercanos
  - **Objetivo:** Clasificar a  $x$  con la etiqueta mas representada (en frecuencia) en los  $k$  patrones mas cercanos a  $x$  de la muestra de entrenamiento global





**FIGURE 4.15.** The  $k$ -nearest-neighbor query starts at the test point  $x$  and grows a spherical region until it encloses  $k$  training samples, and it labels the test point by a majority vote of these samples. In this  $k = 5$  case, the test point  $x$  would be labeled the category of the black points. From: Richard O. Duda, Peter E. Hart, and David G. Stork, *Pattern Classification*. Copyright © 2001 by John Wiley & Sons, Inc.

## Ejemplo:

$k = 3$  (valor impar) y  $x = (0.10, 0.25)^t$

Prototypes	Labels
(0.15, 0.35)	$\omega_1$
(0.10, 0.28)	$\omega_2$
(0.09, 0.30)	$\omega_5$
(0.12, 0.20)	$\omega_2$

Vectores mas cercanos a  $x$  donde sus etiquetas son:

$$\{(0.10, 0.28, \omega_2); (0.12, 0.20, \omega_2); (0.15, 0.35, \omega_1)\}$$

El esquema de votacion asigna la etiqueta  $\omega_2$  a  $x$  pues  $\omega_2$  es el mas representado