

# 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 2  
Bayesian Decision Theory  
(Sections 2.1-2.2)

Bayesian Decision Theory–Continuous Features

# Introduccion

- Estado verdadero  $\omega$  es una variable aleatoria
  - Dos estados verdaderos posibles: Salmon , Mero
- Probabilidades a priori
  - Pesca del Salmon  $P(\omega_1)$
  - Pesca del Mero  $P(\omega_2)$

$$P(\omega_1) + P(\omega_2) = 1$$


- Ejemplo:  $P(\omega_1) = P(\omega_2)$  equiprobables


## Regla de Decision solo con informacion a priori

- Decide  $\omega_1$  si  $P(\omega_1) > P(\omega_2)$  en otro caso decide  $\omega_2$

## Uso de la clase –informacion condicional probabilistica

- $p(x | \omega_1)$  and  $p(x | \omega_2)$  describe la diferencia en tono de las escamas entre poblaciones de Mero y salmon





**FIGURE 2.1.** Hypothetical class-conditional probability density functions show the probability density of measuring a particular feature value  $x$  given the pattern is in category  $\omega_i$ . If  $x$  represents the lightness of a fish, the two curves might describe the difference in lightness of populations of two types of fish. Density functions are normalized, and thus the area under each curve is 1.0. From: Richard O. Duda, Peter E. Hart, and David G. Stork, *Pattern Classification*. Copyright © 2001 by John Wiley & Sons, Inc.

- $P(x, \omega_j)$  probabilidad conjunta de observacion y estado natural


$$P(\omega_j, x) = P(\omega_j | x)p(x) = p(x | \omega_j)P(\omega_j)$$

- Posterior = (Verosimilitud x Prior) / Evidencia

$$P(\omega_j | x) = \frac{p(x | \omega_j)P(\omega_j)}{p(x)}$$

- En el caso de las dos categorias, la evidencia es

$$p(x) = \sum_{j=1}^{j=2} p(x | \omega_j)P(\omega_j)$$



**FIGURE 2.2.** Posterior probabilities for the particular priors  $P(\omega_1) = 2/3$  and  $P(\omega_2) = 1/3$  for the class-conditional probability densities shown in Fig. 2.1. Thus in this case, given that a pattern is measured to have feature value  $x = 14$ , the probability it is in category  $\omega_2$  is roughly 0.08, and that it is in  $\omega_1$  is 0.92. At every  $x$ , the posteriors sum to 1.0. From: Richard O. Duda, Peter E. Hart, and David G. Stork, *Pattern Classification*. Copyright © 2001 by John Wiley & Sons, Inc.

$x$  es una observacion:

si  $P(\omega_1 | x) > P(\omega_2 | x)$   Verdadero estado natural =  $\omega_1$   
si  $P(\omega_1 | x) < P(\omega_2 | x)$   Verdadero Estado Natural =  $\omega_2$

Error

en cuanto observamos un  $x$  particular, la probabilidad de error es :

$$P(\text{error} | x) = P(\omega_1 | x) \text{ si decidimos por } \omega_2$$
$$P(\text{error} | x) = P(\omega_2 | x) \text{ si decidimos por } \omega_1$$

## Regla de Bayes

- Decidir  $\omega_1$  si  $P(\omega_1 | \mathbf{x}) > P(\omega_2 | \mathbf{x})$ ; en otro caso decidir  $\omega_2$

*(regla basada en las probabilidades a posteriori!!)*

- Con esta regla

$$P(\text{error} | \mathbf{x}) = \min [P(\omega_1 | \mathbf{x}), P(\omega_2 | \mathbf{x})]$$

*Produce esta regla el minimo error??*

## *Produce esta regla el minimo error??*

- La probabilidad de error promedio es

$$P(\text{error}) = \int_{-\infty}^{\infty} P(\text{error}, x) dx = \int_{-\infty}^{\infty} P(\text{error} | x) p(x) dx$$

si  $P(\text{error} | x)$  es lo mas chico posible, la integral es la mas chica posible.

Con la regla de Bayes

$$P(\text{error} | x) = \min [P(\omega_1 | x), P(\omega_2 | x)]$$

*por lo cual se garantiza que  $P(\text{error})$  es minimo*

- Descartando la evidencia  $p(x)$ , la regla de Bayes puede expresarse como

Decidir por  $\omega_1$  si

$$p(x | \omega_1) P(\omega_1) > p(x | \omega_2) P(\omega_2);$$

en otro caso decidir por  $\omega_2$

- Si se conoce información adicional,
  - $p(x | \omega_1) = p(x | \omega_2)$ , entonces para ese  $x$  particular, entonces la decisión depende enteramente de las probabilidades a priori .
  - $P(\omega_1) = P(\omega_2)$  entonces la decisión se basa enteramente en las  $p(x | \omega_2)$

# Teoria de Decision Bayesiana

## Caracteristicas continuas

- Generalizacion de las ideas precedentes
  - Usar mas de una caracteristica
  - Usar mas de dos estados verdaderos
  - Permitir acciones y no solo decidir el estado verdadero
  - Introducir una funcion de perdida que es mas general que la probabilidad de error

- Permitir otras acciones además que la clasificación permite la posibilidad de rechazo
- Se niega a tomar una decisión en casos cercanos o en malos casos!
- La función de pérdida dice cuánto cuesta cada acción que se toma

- Sea  $\{\omega_1, \omega_2, \dots, \omega_c\}$  el conjunto de  $c$  estados verdaderos (o “categorias”).
- Sea  $\{\alpha_1, \alpha_2, \dots, \alpha_a\}$  el conjunto de posibles acciones.
- Sea  $\lambda(\alpha_i | \omega_j)$  la perdida incurrida por tomar la accion  $\alpha_i$  cuando el estado verdadero es  $\omega_j$ .
- $X$  es un vector aleatorio y  $p(x|\omega_j)$  es la probabilidad condicional de  $X$  cuando  $\omega_j$  es verdadero.

## Posterior, verosimilitud, evidencia

- *Evidencia Conjunta*

$$P(x) = \sum_{j=1}^c p(x | \omega_j) P(\omega_j)$$

- Posterior = (Verosimilitud x Prior) / Evidencia

$$P(\omega_j | x) = \frac{p(x | \omega_j) P(\omega_j)}{P(x)}$$

Perdida esperada al tomar accion  $\alpha_i$

- Si  $\lambda(\alpha_i | \omega_j)$  es la perdida incurrida por tomar la accion  $\alpha_i$  cuando el estado verdadero es  $\omega_j$ , la perdida esperada es

$$R(\alpha_i | x) = \sum_{j=1}^c \lambda(\alpha_i | \omega_j) P(\omega_j | x)$$

- La pérdida esperada se llama usualmente Riesgo, y  $R(\alpha_i | x)$  es el *Riesgo condicional*
- Se busca una regla que minimize el Riesgo completo

$$R = \int R(\alpha | x) p(x)$$

Minimizar R



Minimizar  $R(\alpha_i | x)$  para  $i = 1, \dots, a$

$$R(\alpha_i | x) = \sum_{j=1}^c \lambda(\alpha_i | \omega_j) P(\omega_j | x) \quad i = 1, \dots, a$$

Seleccionar la acción  $\alpha_i$  para la cual  $R(\alpha_i | x)$  es mínimo



R es mínimo

R en ese caso se llama el riesgo de Bayes  
el mejor desempeño posible!

- Clasificación de dos categorías

$\alpha_1$  : decide por  $\omega_1$

$\alpha_2$  : decide por  $\omega_2$

$$\lambda_{ij} = \lambda(\alpha_i | \omega_j)$$

Perdida incurrida al decidir por  $\omega_i$  cuando el verdadero estado natural es  $\omega_j$

Riesgo condicional:

$$R(\alpha_1 | \mathbf{x}) = \lambda_{11}P(\omega_1 | \mathbf{x}) + \lambda_{12}P(\omega_2 | \mathbf{x})$$

$$R(\alpha_2 | \mathbf{x}) = \lambda_{21}P(\omega_1 | \mathbf{x}) + \lambda_{22}P(\omega_2 | \mathbf{x})$$

La regla de Bayes es la siguiente :

$$\text{si } R(\alpha_1 | x) < R(\alpha_2 | x)$$

se toma la accion  $\alpha_1$ : “decide por  $\omega_1$ ”

Regla1

“ Decidir por  $\omega_1$  si:

$$(\lambda_{21} - \lambda_{11}) p(x | \omega_1) P(\omega_1) > (\lambda_{12} - \lambda_{22}) p(x | \omega_2) P(\omega_2)$$

decidir por  $\omega_2$  en otro caso”

## Regla 2:

Si suponemos  $\lambda_{21} > \lambda_{11}$

$$\frac{p(x | \omega_1)}{p(x | \omega_2)} > \frac{\lambda_{12} - \lambda_{22}}{\lambda_{21} - \lambda_{11}} \cdot \frac{P(\omega_2)}{P(\omega_1)}$$

Entonces tome accion  $\alpha_1$  (decida por  $\omega_1$ )

En otro caso tome accion  $\alpha_2$  (decida por  $\omega_2$ )

## Propiedad de decision optima

“Si el cociente de verosimilitudes excede el valor de un umbral que es independiente del patron ingresado  $x$ , se pueden tomar decisiones optimas”

# Densidad Normal


- Univariada
  - Densidad analíticamente manejable
  - Densidad continua
  - Muchos procesos son asintóticamente gaussianos
  - Caracteres escritos a mano, sonidos del habla se modelan como prototipos corruptos por un proceso aleatorio

$$P(x) = \frac{1}{\sqrt{2\pi} \sigma} \exp\left[-\frac{1}{2}\left(\frac{x - \mu}{\sigma}\right)^2\right],$$

Donde:

$\mu$  = esperanza de  $x$

$\sigma^2$  = varianza



**FIGURE 2.7.** A univariate normal distribution has roughly 95% of its area in the range  $|x - \mu| \leq 2\sigma$ , as shown. The peak of the distribution has value  $p(\mu) = 1/\sqrt{2\pi}\sigma$ . From: Richard O. Duda, Peter E. Hart, and David G. Stork, *Pattern Classification*. Copyright © 2001 by John Wiley & Sons, Inc.

## Ejemplo

Seleccionar la decision optima cuando :

$$\Omega = \{\omega_1, \omega_2\}$$

$$p(x | \omega_1) \quad \longrightarrow \quad N(2, 0.5) \text{ (distribucion Normal)}$$

$$p(x | \omega_2) \quad \longrightarrow \quad N(1.5, 0.2)$$

$$P(\omega_1) = 2/3$$

$$P(\omega_2) = 1/3$$

$$\lambda = \begin{bmatrix} 1 & 2 \\ 3 & 0.4 \end{bmatrix}$$

*La condicion que deben cumplir los  $\lambda$  son  $\lambda_{21} > \lambda_{11}$ ,  $\lambda_{12} > \lambda_{22}$*

# Ejemplo

$$\frac{p(x | \omega_1)}{p(x | \omega_2)} > \frac{\lambda_{12} - \lambda_{22}}{\lambda_{21} - \lambda_{11}} \cdot \frac{P(\omega_2)}{P(\omega_1)}$$

$$\frac{\frac{1}{\sqrt{2\pi} \cdot 0.5} \exp\left[-\frac{1}{2} \left(\frac{x-2}{0.5}\right)^2\right]}{\frac{1}{\sqrt{2\pi} \cdot 0.2} \exp\left[-\frac{1}{2} \left(\frac{x-1.5}{0.2}\right)^2\right]} > \frac{2-0.4}{3-1} \cdot \frac{2/3}{1/3}$$

$$2 * \ln(0.2 / 0.5) - \left(\frac{x-2}{0.5}\right)^2 + \left(\frac{x-1.5}{0.2}\right)^2 > 1.6$$