

# MAT-269: Sesión 20, Análisis Discriminante I

Felipe Osorio

[fosorios.mat.utfsm.cl](mailto:fosorios.mat.utfsm.cl)

Departamento de Matemática, UTFSM



# Análisis discriminante

Suponga observaciones multivariadas provenientes de  $g$  clases (o grupos) predefinidos teniendo características similares.

## *Ejemplos:*

Especies de plantas, Niveles de solvencia para clientes de un banco, presencia/ausencia de una condición médica, tipos de tumores, si un mensaje es SPAM o no, etc.

## Se desea:

- (a) **Discriminar**, esto es usar la información de aquellas **observaciones similares** para construir una **regla de clasificación** que permita separar tanto como sea posible las clases predefinidas.
- (b) **Clasificar**, dada las mediciones de una **nueva** observación **predecir** a que clase pertenece.



## Análisis discriminante

Cuando existe sólo dos clases ( $g = 2$ ) se requiere de **un único** clasificador, mientras que cuando se dispone de más clases se necesita al menos dos (y a lo más  $g - 1$ ) clasificadores para diferenciar entre clases.

Suponga una población  $\mathcal{P}$  particionada en  $g$  grupos denotados por  $\Pi_1, \dots, \Pi_g$ . Además, cada elemento de  $\mathcal{P}$  es clasificado **sólo** en una clase.

Las mediciones de una muestra son usadas para asignar observaciones futuras a las clases designadas.

El vector aleatorio  $\mathbf{x} = (x_1, \dots, x_p)^\top$  representa las  $p$  mediciones de un ítem, las que son escogidas por su habilidad para distinguir entre las  $g$  clases.



Considere  $g = 2$ , y deseamos discriminar entre las clases  $\Pi_1$  y  $\Pi_2$ .

## Regla de clasificación de Bayes

Sea

$$P(\mathbf{x} \in \Pi_i) = \pi_i, \quad i = 1, 2,$$

la probabilidad a priori de que una observación  $\mathbf{x}$  seleccionada al azar, pertenezca a  $\Pi_1$  o  $\Pi_2$ .

Suponga que asociado a la  $i$ -ésima clase, existe una densidad

$$P(\mathbf{X} = \mathbf{x} | \mathbf{X} \in \Pi_i) = f_i(\mathbf{x}), \quad i = 1, 2$$

(no se realizan supuestos sobre  $f_i$ )



Considere  $g = 2$ , y deseamos discriminar entre las clases  $\Pi_1$  y  $\Pi_2$ .

## Regla de clasificación de Bayes

Sea

$$P(\mathbf{x} \in \Pi_i) = \pi_i, \quad i = 1, 2,$$

la probabilidad a priori de que una observación  $\mathbf{x}$  seleccionada al azar, pertenezca a  $\Pi_1$  o  $\Pi_2$ .

Suponga que asociado a la  $i$ -ésima clase, existe una densidad

$$P(\mathbf{X} = \mathbf{x} | \mathbf{X} \in \Pi_i) = f_i(\mathbf{x}), \quad i = 1, 2$$

(no se realizan supuestos sobre  $f_i$ )



El teorema de Bayes, permite obtener la probabilidad a posteriori

$$p(\Pi_i|\mathbf{x}) = P(\mathbf{X} \in \Pi_i|\mathbf{X} = \mathbf{x}) = \frac{f_i(\mathbf{x})\pi_i}{f_1(\mathbf{x})\pi_1 + f_2(\mathbf{x})\pi_2},$$

esto es la probabilidad de que el  $\mathbf{x}$  observado pertenezca a  $\Pi_i$ ,  $i = 1, 2$ .

Para un  $\mathbf{x}$  dado, una estrategia de clasificación razonable es asignar  $\mathbf{x}$  a la clase con mayor densidad a posterior.

La **regla clasificadora de Bayes** es: asignar  $\mathbf{x}$  a  $\Pi_1$  si

$$\frac{p(\Pi_1|\mathbf{x})}{p(\Pi_2|\mathbf{x})} > 1,$$

y asignamos  $\mathbf{x}$  a  $\Pi_2$  en caso contrario.



## *Observación:*

Note que el clasificador de Bayes asigna  $\mathbf{x}$  a  $\Pi_1$  si

$$\frac{f_1(\mathbf{x})}{f_2(\mathbf{x})} > \frac{\pi_2}{\pi_1},$$

y a  $\Pi_2$  en caso contrario.



## Análisis discriminante lineal gaussiano

Suponiendo que ambas densidades siguen una distribución normal multivariada, la regla de Bayes adopta la forma propuesta por Fisher (1936).

Suponga que  $f_1(\cdot)$  es una  $N_p(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1)$  y  $f_2(\cdot)$  es  $N_p(\boldsymbol{\mu}_2, \boldsymbol{\Sigma}_2)$  con el supuesto adicional de homogeneidad, es decir  $\boldsymbol{\Sigma}_1 = \boldsymbol{\Sigma}_2 = \boldsymbol{\Sigma}$ .

La razón de las dos densidades está dada por

$$\frac{f_1(\mathbf{x})}{f_2(\mathbf{x})} = \frac{\exp\{-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_1)^\top \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu}_1)\}}{\exp\{-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_2)^\top \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu}_2)\}},$$

tomando logaritmos

$$\begin{aligned}\log \frac{f_1(\mathbf{x})}{f_2(\mathbf{x})} &= -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_1)^\top \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu}_1) + \frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_2)^\top \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu}_2) \\ &= (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^\top \boldsymbol{\Sigma}^{-1} \mathbf{x} - \frac{1}{2}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^\top \boldsymbol{\Sigma}^{-1}(\boldsymbol{\mu}_1 + \boldsymbol{\mu}_2) \\ &= (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^\top \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \bar{\boldsymbol{\mu}}), \quad \bar{\boldsymbol{\mu}} = \frac{1}{2}(\boldsymbol{\mu}_1 + \boldsymbol{\mu}_2).\end{aligned}$$





Note además que

$$(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^\top \boldsymbol{\Sigma}^{-1}(\boldsymbol{\mu}_1 + \boldsymbol{\mu}_2) = \boldsymbol{\mu}_1^\top \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_1 - \boldsymbol{\mu}_2^\top \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_2,$$

luego sigue que

$$L(\boldsymbol{x}) = \log\left(\frac{f_1(\boldsymbol{x})\pi_1}{f_2(\boldsymbol{x})\pi_2}\right) = b_0 + \mathbf{b}^\top \boldsymbol{x},$$

es una función lineal de  $\boldsymbol{x}$ , donde

$$\mathbf{b} = \boldsymbol{\Sigma}^{-1}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)$$

$$b_0 = -\frac{1}{2}(\boldsymbol{\mu}_1^\top \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_1 - \boldsymbol{\mu}_2^\top \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_2) + \log(\pi_2/\pi_1).$$

## Regla de clasificación:

Si  $L(\boldsymbol{x}) > 0$ , asignar  $\boldsymbol{x}$  a  $\Pi_1$  y en caso contrario asignar  $\boldsymbol{x}$  a  $\Pi_2$ .



$L(\mathbf{x})$  define un hiperplano que divide las dos clases. La regla anterior se conoce como **Análisis discriminante lineal (LDA)** gaussiano.

La función

$$U(\mathbf{x}) = \mathbf{b}^\top \mathbf{x} = (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^\top \boldsymbol{\Sigma}^{-1} \mathbf{x},$$

se conoce como la **función discriminante lineal de Fisher (LDF)**.



La LDF particiona la población  $\mathcal{P}$  en regiones de clasificación disjuntas  $R_1$  y  $R_2$ . Si  $x$  se asigna a la región  $R_1$  la misma es clasificada como perteneciente a  $\Pi_1$  en otro caso  $x$  se asigna a  $R_2$  y es clasificada en  $\Pi_2$

Se puede cometer los siguientes errores (mala clasificación):

- (a) Asignar  $x$  a  $\Pi_2$  cuando pertenece a  $\Pi_1$ .
- (b) Asignar  $x$  a  $\Pi_1$  cuando pertenece a  $\Pi_2$ .



Defina

$$\Delta^2 = (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^\top \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2),$$

la **distancia de Mahalanobis** entre  $\Pi_1$  y  $\Pi_2$ . Entonces

$$E(U|\mathbf{x} \in \Pi_i) = (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^\top \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_i,$$

y

$$\begin{aligned} \text{var}(U|\mathbf{x} \in \Pi_i) &= \mathbf{b}^\top \boldsymbol{\Sigma} \mathbf{b} = (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^\top \boldsymbol{\Sigma}^{-1} \boldsymbol{\Sigma} \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) \\ &= \Delta^2, \end{aligned}$$

para  $i = 1, 2$ .



## Probabilidad total de mala clasificación

La probabilidad de mala clasificación total es:

$$P(\Delta) = P(\mathbf{x} \in R_2 | \mathbf{x} \in \Pi_1)\pi_1 + P(\mathbf{x} \in R_1 | \mathbf{x} \in \Pi_2)\pi_2,$$

donde

$$\begin{aligned} P(\mathbf{x} \in R_2 | \mathbf{x} \in \Pi_1) &= P(L(\mathbf{x}) < 0 | \mathbf{x} \in \Pi_1) \\ &= P\left(Z < -\frac{\Delta}{2} - \frac{1}{\Delta} \log \frac{\pi_2}{\pi_1}\right) \\ &= \Phi\left(-\frac{\Delta}{2} - \frac{1}{\Delta} \log \frac{\pi_2}{\pi_1}\right) \end{aligned}$$

y análogamente

$$\begin{aligned} P(\mathbf{x} \in R_1 | \mathbf{x} \in \Pi_2) &= P(L(\mathbf{x}) > 0 | \mathbf{x} \in \Pi_2) \\ &= P\left(Z > \frac{\Delta}{2} - \frac{1}{\Delta} \log \frac{\pi_2}{\pi_1}\right) \\ &= \Phi\left(-\frac{\Delta}{2} + \frac{1}{\Delta} \log \frac{\pi_2}{\pi_1}\right) \end{aligned}$$



En el cálculo de estas probabilidades se usa el hecho que  $L(\mathbf{x}) = b_0 + U(\mathbf{x})$  y se estandariza  $U$  como

$$Z = \frac{U - E(U|\mathbf{x} \in \Pi_i)}{\sqrt{\text{var}(U|\mathbf{x} \in \Pi_i)}}.$$

Si  $\pi_1 = \pi_2 = \frac{1}{2}$ , entonces

$$P(\mathbf{x} \in R_2|\mathbf{x} \in \Pi_1) = P(\mathbf{x} \in R_1|\mathbf{x} \in \Pi_2) = \Phi(-\Delta/2),$$

y de ahí que

$$P(\Delta) = 2\Phi(-\Delta/2).$$

### *Observación:*

Note que  $P(\Delta) = 1$  cuando  $\Delta = 0$  es decir, las dos poblaciones son idénticas y tiende a cero conforme  $\Delta$  crece. Es decir, mientras mayor sea la distancia entre las dos medias poblacionales menos probable es clasificar erróneamente  $\mathbf{x}$ .

