

# ESTADÍSTICA

- Aplica la probabilidad al estudio de datos experimentales.
- Realizamos una medida  $N$  veces, obteniendo un conjunto  $\{x_i\}_{i \in \{1, \dots, N\}} \Rightarrow$  MUESTRA
- Tanto cada uno de los  $x_i$  como el conjunto  $\vec{x} = (x_1, \dots, x_N)$  son variables aleatorias (que tienen una serie de valores posibles, con cierta probabilidad). Nuestro objetivo es hallar su distribución de probabilidad o población.

- Las variables se dicen estadísticamente independientes, si la medida de una no afecta a las posteriores. En ese caso,  $p(\vec{x}) = \prod_i p_i(x_i)$
- Si además todas las  $p_i$  son iguales (lo cual no ocurre, por ejemplo, si yo mido con más precisión algunos datos) la muestra se dice aleatoria de tamaño  $N$  de la población  $p(x)$
- Salvo que se diga lo contrario, nos centraremos en este último caso.

En general,  $p(x_i)$  dependerá de unos parámetros  $\vec{a} = (a_1, \dots, a_m)$ . Nuestro objetivo es, dado  $\{x_i\}$  hallar  $\vec{a}$  y determinar  $p = p(x_i | \vec{a})$ .

## ESTADÍSTICOS

• Son funciones de la muestra. Ejemplos:

de la muestra, NO de la población

$$\langle x \rangle = \frac{1}{N} \sum x_i \rightarrow \text{Medio}$$

$$\overline{x^2} = \sqrt{\langle x^2 \rangle} \rightarrow \text{Ejemplo estadístico medio (root-mean square)}$$

$$s^2 = \frac{1}{N} \sum (x_i - \langle x \rangle)^2 \rightarrow \text{Varianza}$$

$$\sigma = \sqrt{s^2} \rightarrow \text{Desviación típica}$$

$$m_n = \langle x^n \rangle \rightarrow \text{Momento}$$

$$m_n = \langle (x - \langle x \rangle)^n \rangle \rightarrow \text{Momento central}$$

$$g_n = \frac{m_n}{m_2^{n/2}} \rightarrow \text{Momento central normalizado}$$

Si se nido parejas de valores  $(x_i, y_i)$ , es útil definir:

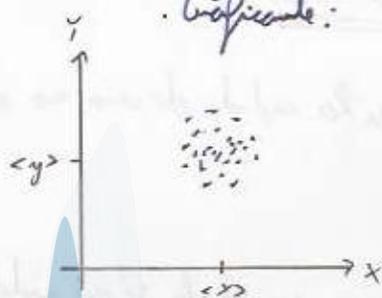
$$V_{xy} = \frac{1}{N} \sum_{i=1}^N (x_i - \langle x \rangle)(y_i - \langle y \rangle) = \langle xy \rangle - \langle x \rangle \langle y \rangle \rightarrow \text{Covarianza}$$

$$r_{xy} = \frac{V_{xy}}{\sigma_x \sigma_y} \rightarrow \text{correlación}$$

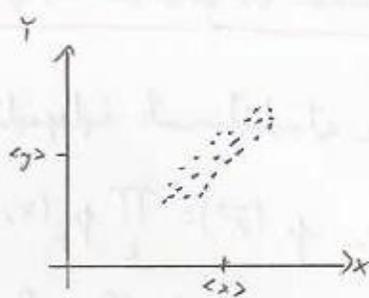
•  $r_{xy} \in [-1, 1]$

•  $x$  y  $y$  independientes  $\Rightarrow r_{xy} = 0$

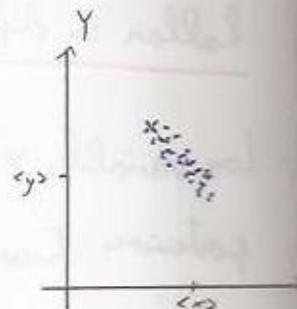
• Gráficas:



$r_{xy} = 0$



$r_{xy} \sim 1$



$r_{xy} \sim -1$

Zimatek

## ESTIMADORES

- Sima para estimar los parámetros  $\{a_i\}$ . Se denotan por  $\hat{a}_i$
- Son, en general, función de la muestra:

$$\hat{a} = \hat{a}(\bar{x})$$

- Como depende de los datos, es una variable aleatoria  $\Rightarrow$  podemos definir una distribución de probabilidad:

$$p(\hat{a}|a) d\hat{a} = p(\bar{x}|a) d^N x$$

- Deben cumplir:

1- CONSISTENCIA:  $\lim_{N \rightarrow \infty} \hat{a}(\bar{x}) = a$

2- BIAS:  $b(\hat{a}) \equiv \langle \hat{a} \rangle - a$ ; con  $\langle \hat{a} \rangle = \int p(\hat{a}|a) \hat{a} d\hat{a} = \int p(\bar{x}|a) \hat{a}(\bar{x}) d^N x$   
Por consistencia,  $\lim_{N \rightarrow \infty} b(\hat{a}) = 0$

3- EFICIENCIA: Sea la varianza  $V(\hat{a}) = \langle (\hat{a} - \langle \hat{a} \rangle)^2 \rangle$

Si la varianza es pequeña, el estimador se dice eficiente.

Cuando al límite de Fisher:

$$V(\hat{a}) \geq \frac{1 + \frac{\partial b}{\partial a}}{\langle -\frac{\partial^2 \ln p}{\partial a^2} \rangle} \quad ; \text{ con } \begin{cases} b \text{ el bias} \\ p = p(\bar{x}|a) \end{cases}$$

- Estimadores importantes:

• MEDIA: - Si todas las  $p_i$  tienen la misma  $\sigma$ :  $\bar{x} \equiv \frac{1}{N} \sum_i x_i$

- Si cada  $p_i$  tiene una  $\sigma_i$ :  $\bar{x} \equiv \frac{\sum_i x_i / \sigma_i^2}{\sum_i 1 / \sigma_i^2}$

• DESVIACIÓN TÍPICA:  $\hat{\sigma} \equiv \sqrt{\frac{\sum_i (x_i - \bar{x})^2}{N-1}}$

Ejemplo: estimador  $\bar{x}$ , y distribución subyacente normal:  $p(\bar{x}|\mu, \sigma) = \prod_i \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x_i - \mu)^2}{2\sigma^2}}$

Para  $N$  suficientemente grande, por T.C.L.,  $p(\bar{x}|\mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2/N}} e^{-\frac{(\bar{x} - \mu)^2}{2\sigma^2/N}}$

Entonces, VN

Consistencia:  $p(\bar{x}|\mu, \sigma) \xrightarrow{N \rightarrow \infty} \delta(\bar{x} - \mu) \Rightarrow \bar{x}$  sólo puede tomar el valor  $\mu$   
 $\Downarrow$   
 $\langle \bar{x} \rangle \rightarrow \mu$

Primer:  $\langle \bar{x} \rangle = \mu$  para  $N$  suficientemente grande (pues es una función centrada en  $\mu$ )

$$b = \langle \bar{x} \rangle - \mu = 0 \text{ (en este caso es una igualdad } \forall N)$$

Eficiencia: Al ser una función normal,  $V(\bar{x}) = \frac{\sigma^2}{N}$ . Esto satura el límite de Fisher

(la eficiencia es máxima):

$$\frac{\partial l}{\partial \mu} = 0$$

$$\frac{\partial^2 l}{\partial \mu^2} = \frac{\partial^2}{\partial \mu^2} \left[ -\frac{1}{2} \sum_i \left[ \ln(2\pi\sigma^2) + \frac{(x_i - \mu)^2}{\sigma^2} \right] \right] =$$

$$= -\frac{N}{\sigma^2}$$

$$\frac{1 + \frac{\partial l}{\partial \mu}}{\left\langle -\frac{\partial^2 l}{\partial \mu^2} \right\rangle} = \frac{\sigma^2}{N}$$

## ERRORES EN LOS ESTIMADORES

El error se suele expresar:

Si el bias = 0, se usa el error estándar

$$\sigma_{\hat{a}} = \sqrt{V[\hat{a}]}$$

Si el bias  $\neq 0$ , se toma el error cuadrático medio

$$\varepsilon_{\hat{a}} = \sqrt{\langle (\hat{a} - a)^2 \rangle} = \sqrt{V(\hat{a}) + b(a)^2}$$

Derivación:

$$\begin{aligned} \langle (\hat{a} - a)^2 \rangle &= \langle (\hat{a} - \langle \hat{a} \rangle + \langle \hat{a} \rangle - a)^2 \rangle = \\ &= \langle (\hat{a} - \langle \hat{a} \rangle)^2 - 2(\hat{a} - \langle \hat{a} \rangle)(\langle \hat{a} \rangle - a) + (\langle \hat{a} \rangle - a)^2 \rangle = \\ &= \langle (\hat{a} - \langle \hat{a} \rangle)^2 \rangle + 2\langle \hat{a} - \langle \hat{a} \rangle \rangle \langle \hat{a} \rangle - a \rangle + \langle \langle \hat{a} \rangle - a \rangle^2 \\ &\quad \text{"} \quad \quad \quad \langle \hat{a} \rangle - \langle \hat{a} \rangle = 0 \quad \quad \quad \text{"} \\ &\quad V(\hat{a})^2 \quad b(a)^2 \end{aligned}$$

En el ejemplo de  $\bar{x}$ , al no tener bias,  $\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{N}}$  para  $N$  infinitamente grande para poder aplicar T.C.L. Para otras condiciones error, propagado errores,  $\sigma_{\bar{x}} = \frac{1}{\sum \frac{1}{\sigma_i^2}}$

## INTERVALOS DE CONFIANZA

Una vez dado el error:  $a \in [a_-, a_+]$

$$a = \hat{a} + d = a_+ - \hat{a}$$
$$-c = \hat{a} - a_-$$

$$a = \hat{a} \pm b \quad d=c=b$$

Nos gustaría dar la probabilidad de que  $a$  esté en el intervalo dado. Esto se le conoce como nivel de confianza.

Para ello, definimos  $\forall \alpha, \beta \in [0, 1]$ :

$$\hat{a}_\alpha(a) \text{ cumple } P(\hat{a} \leq \hat{a}_\alpha(a) | a) = \alpha$$

$$\hat{a}_\beta(a) \text{ cumple } P(\hat{a} \geq \hat{a}_\beta(a) | a) = \beta$$

→ Ejemplo: la distribución de probabilidad de  $\hat{a}$  está fijo. Me pregunto por el punto tal que el área entre  $-\infty$  y  $\hat{a}$  que vale  $\alpha$

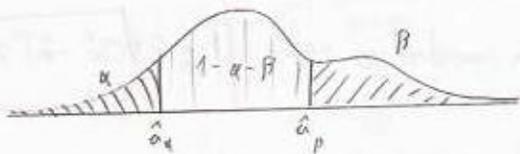
Son funciones de  $\alpha, \beta$  y  $a$

↓  
Es la distribución de probabilidad de  $\hat{a}$  de grado de  $a$

Ans:

$$P(\hat{a}_\alpha(a) \leq \hat{a} \leq \hat{a}_\beta(a)) = 1 - \alpha - \beta$$

Distribución que sea



Supongamos que, dada una muestra, estimo el valor  $\hat{a}_{obs}$ . Defino  $\forall \alpha, \beta \in [0, 1]$ :

$$a_+ = \hat{a}_\alpha^{-1}(\hat{a}_{obs})$$

$$a_- = \hat{a}_\beta^{-1}(\hat{a}_{obs})$$

¿Con qué valores de  $a$  tengo que fijar la distribución para que el área entre  $-\infty$  y  $\hat{a}_{obs}$  sea  $\alpha$ ?

luego:

$$P(a_+ < a) = \alpha$$

$$P(a_- > a) = \beta$$

Zimatek

Por lo que:

$$P(a_- \leq a \leq a_+) = 1 - \alpha - \beta$$

Si  $\alpha = \beta$ , el intervalo de confianza se dice centrado

Ejemplo: Gaussiana

$$P(\hat{a}|a) = \frac{1}{\sqrt{2\pi\sigma_{\hat{a}}^2}} e^{-\frac{(\hat{a}-a)^2}{2\sigma_{\hat{a}}^2}}$$

$$\text{An: } \alpha = \int_{-\infty}^{\hat{a}_\alpha} d\hat{a} \frac{1}{\sqrt{2\pi\sigma_{\hat{a}}^2}} e^{-\frac{(\hat{a}-a)^2}{2\sigma_{\hat{a}}^2}}$$

$$\Updownarrow$$
$$\alpha = \Phi\left(\frac{\hat{a}_\alpha - a}{\sigma_{\hat{a}}}\right)$$

$\Updownarrow$

$$\hat{a}_\alpha(a) = a + \sigma_{\hat{a}} \Phi^{-1}(\alpha)$$

Análogo,

$$\hat{a}_\beta(a) = a - \sigma_{\hat{a}} \Phi^{-1}(\beta)$$

De esta manera:

$$\hat{a}_{obs} = a_+ + \sigma_{\hat{a}} \Phi^{-1}(\alpha); \quad a_+ = \hat{a}_{obs} - \sigma_{\hat{a}} \Phi^{-1}(\alpha)$$
$$\hat{a}_{obs} = a_- - \sigma_{\hat{a}} \Phi^{-1}(\beta); \quad a_- = \hat{a}_{obs} + \sigma_{\hat{a}} \Phi^{-1}(\beta)$$

Entonces:

$$a_- = \hat{a}_{obs} - \sigma_{\hat{a}} \Phi^{-1}(1-\beta)$$

$$a_+ = \hat{a}_{obs} + \sigma_{\hat{a}} \Phi^{-1}(1-\alpha)$$

An, dados  $\alpha$  y  $\beta$  (las probabilidades con las que queremos dar nuestros errores), somos capaces de hallar los extremos del error,  $a_+$  y  $a_-$ .

Vicerversa, dados  $a_+$  y  $a_-$ , es fácil obtener  $\alpha$  y  $\beta$ , sin más que explicar que

$$\hat{a}_{obs} = \hat{a}_\alpha(a_+) \Rightarrow \alpha = P(\hat{a} \leq \hat{a}_{obs} | a_+) \rightarrow \text{En el caso, en la distribución y valores de } \hat{a}$$

entre  $\hat{a}_{obs}$  y los extremos  $(a_+ \text{ y } a_-)$

Er la Gaussiana, per il 68%:

$$a = \hat{a}_{obs} \pm \sigma_a \Rightarrow 68\%$$

$$a = \hat{a}_{obs} \pm 2\sigma_a \Rightarrow 95.4\%$$

$$a = \hat{a}_{obs} \pm 3\sigma_a \Rightarrow 99.7\%$$



Zimatek