

# Probabilidad - Clase 24

## Simulación - Estadística

Ernesto Mordecki

Facultad de Ciencias, Universidad de la República. Montevideo, Uruguay

Curso de la Licenciatura en Matemática - 2020

# Contenidos

Simulación de un vectores gaussianos bidimensional  
(Box-Muller)

V.a. i.i.d - m.a.s

Estadística: Estimación de un parámetro

Estimador de un parámetro

Estimador de máxima verosimilitud

Ejemplo: estimación del  $a$  en el caso normal



Estimación de  $a, b$  en el modelo uniforme

# Inversa generalizada de una distribución

Para  $F: \mathbb{R} \rightarrow [0, 1]$  función de distribución, se define su inversa generalizada

$$F^{-1}(p) = \inf\{x \in \mathbb{R} : F(x) \geq p\}, \quad \text{para } 0 < p < 1.$$

$$F^{-1}(p) = \begin{cases} 0, & \text{cuando } 0 < p \leq 4/9 \\ 1, & \text{cuando } 4/9 < p \leq 8/9 \\ 2, & \text{cuando } 8/9 < p \leq 1 \end{cases}$$



# Simulación de un vectores gaussianos bidimensional (Box-Muller)

Como la función

$$\Phi(x) = \int_{-\infty}^x \varphi(t) dt,$$

no tiene fórmula elemental, no se puede aplicar el método de la transformación inversa.

**Teorema (Método de Box-Muller)** Sean  $U, V$  dos variables aleatorias uniformes independientes. Entonces

$$(X, Y) = \left( \sqrt{-2 \log(U)} \sin(2\pi V), \sqrt{-2 \log(U)} \cos(2\pi V) \right)$$

es un vector normal bivariado con<sup>1</sup>

$$\mu = \begin{pmatrix} 0 \\ 0 \end{pmatrix}, \quad \Sigma = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

---

<sup>1</sup>  $\mu$  es el  $a$  de antes.

# Demostración

Sea  $A \subset \mathbb{R}^2$ . Se tiene que

$$P((X, Y) \in A) = \iint_{(\sqrt{-2 \log(u)} \sin(2\pi v), \sqrt{-2 \log(u)} \cos(2\pi v)) \in A} dudv$$

Hacemos el cambio de variable

$$g(u, v) = (\sqrt{-2 \log(u)} \sin(2\pi v), \sqrt{-2 \log(u)} \cos(2\pi v)) = (x, y)$$

Despejando en términos de  $u$  y  $v$  tenemos que

$$g^{-1}(x, y) = \left( e^{\frac{-x^2 - y^2}{2}}, \frac{1}{2\pi} \arctan(y/x) \right)$$

Calculemos el jacobiano:  $\mathbb{J}_{g^{-1}}(x, y)$

$$\begin{aligned} \mathbb{J}_{g^{-1}}(x, y) &= \left| \begin{array}{cc} e^{\frac{-x^2-y^2}{2}}(-x) & e^{\frac{-x^2-y^2}{2}}(-y) \\ \frac{1}{2\pi(1+(y/x)^2)}(-y/x^2) & \frac{1}{2\pi(1+(y/x)^2)}(1/x^2) \end{array} \right| \\ &= \frac{1}{2\pi} e^{-\frac{1}{2}(x^2+y^2)} \end{aligned}$$

Luego,

$$\begin{aligned} P((X, Y) \in A) &= \iint_{(\sqrt{-2\log(u)} \sin(2\pi v), \sqrt{-2\log(u)} \cos(2\pi v)) \in A} dudv \\ &= \frac{1}{2\pi} \iint_{(x,y) \in A} e^{-\frac{1}{2}(x^2+y^2)} dx dy \end{aligned}$$

## v.a. i.i.d - m.a.s

- ▶ Un concepto central en probabilidad y estadística lo conforman un conjunto

$$X_1, X_2, \dots, X_n$$

de variables aleatorias independientes con distribución común.

- ▶ En probabilidad, decimos que se trata de ***n* variables aleatorias independientes con idéntica distribución**, y se abrevia **v.a. i.i.d.**
- ▶ En estadística, decimos que se trata de una **muestra aleatoria simple**: y se abrevia **m.a.s.**

- ▶ Sea  $F(x)$  la distribución común de las variables,  $p(x)$  su densidad,  $p_k$  la probabilidad en el caso discreto.
- ▶ La distribución del vector  $X = (X_1, X_2, \dots, X_n)$  viene dada por

$$F(x_1, \dots, x_n) = F(x_1) \dots F(x_n)$$

- ▶ En caso de ser continuas, la densidad conjunta es

$$p(x_1, \dots, x_n) = p(x_1) \dots p(x_n)$$

- ▶ En el caso discreto, la probabilidad conjunta es

$$P(X_1 = k_1, \dots, X_n = k_n) = p_{k_1} \dots p_{k_n}.$$



# Estadística: Estimación de un parámetro

Supongamos la siguiente situación estadística:

- ▶ Observamos el resultado numérico de  $n$  experimentos que se realizan en forma independiente y bajo las mismas condiciones.
- ▶ Es válido suponer que lo que observamos es una muestra aleatoria simple  $X_1, \dots, X_n$
- ▶ Dichas variables dependen de un parámetro  $\theta$  que desconocemos
- ▶ Queremos a partir de la observación tener una idea del valor verdadero de  $\theta$

# Estimador de un parámetro

- ▶ Se trata de calcular una aproximación de  $\theta \in \mathbb{R}$  (valor teórico desconocido), que denotamos  $\hat{\theta}$ , a partir de  $X_1, \dots, X_n$ .
- ▶ Más formalmente escribimos

$$\hat{\theta}_n = f(X_1, \dots, X_n).$$

es decir, un *estimador* es una función  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ .

- ▶ Si bien no es una condición de la definición, se espera que  $\hat{\theta}_n$  sea cercano a  $\theta$ , o converga a  $\theta$  en algún sentido.
- ▶ A veces distinguimos con la notación  $x_1, \dots, x_n$  (dato observado) de  $X_1, \dots, X_n$  (variable aleatoria a observar)

# Estimador de máxima verosimilitud

Vamos a usar la misma estrategia que antes:

- ▶ escribimos la densidad (o la probabilidad en el caso discreto) como función de la muestra, y obtenemos al variar  $\theta$  el máximo valor posible de esa densidad.
- ▶ definimos entonces la *verosimilitud*

$$L(\theta, x_1, \dots, x_n) := p(x_1, \theta) \dots p(x_n, \theta)$$

- ▶ definimos

$$\hat{\theta} = \arg \max_{\theta \in \mathbb{R}} L(\theta, x_1, \dots, x_n)$$

- ▶ Muchas veces es útil definir la *log-verosimilitud*:

$$\begin{aligned}\ell(\theta, x_1, \dots, x_n) &:= \log p(x_1, \theta) \dots p(x_n, \theta) \\ &= \sum_{k=1}^n \log p(x_k, \theta).\end{aligned}$$

- ▶ Como el logaritmo es una función monótona, tenemos

$$\hat{\theta}_n = \arg \max_{\theta \in \mathbb{R}} \ell(\theta, x_1, \dots, x_n)$$

- ▶ El mismo valor que maximiza  $L$  es el que maximiza  $\ell$ .

## Ejemplo: estimación del $a$ en el caso normal

- ▶ Supongamos que sabemos que los datos siguen una distribución normal, conocemos el parámetro de escala  $\sigma^2$  pero desconocemos el parámetro de posición  $a$ .
- ▶ Eso puede corresponder a mediciones con un aparato que introduce un error  $\sigma^2$  conocido.
- ▶ Nuestro parámetro de interés es entonces  $a$ .
- ▶ Veamos entonces si obtenemos  $f$  para tener una estimación

La densidad normal es

$$p(x, a) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-a}{\sigma}\right)^2}$$

La verosimilitud es entonces

$$\begin{aligned} L(a, x_1, \dots, x_n) &= \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x_1-a}{\sigma}\right)^2} \dots \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x_n-a}{\sigma}\right)^2} \\ &= \left(\frac{1}{\sigma\sqrt{2\pi}}\right)^n e^{-\frac{1}{2}\sum_{k=1}^n \left(\frac{x_k-a}{\sigma}\right)^2} \end{aligned}$$

Por eso la log-verosimilitud es

$$\begin{aligned} \ell(a, x_1, \dots, x_n) &= \log \left[ \left(\frac{1}{\sigma\sqrt{2\pi}}\right)^n e^{-\frac{1}{2}\sum_{k=1}^n \left(\frac{x_k-a}{\sigma}\right)^2} \right] \\ &= n \log \left(\frac{1}{\sigma\sqrt{2\pi}}\right) - \frac{1}{2} \sum_{k=1}^n \left(\frac{x_k-a}{\sigma}\right)^2 \end{aligned}$$

El primer sumando no depende de  $a$ . Tenemos entonces que minimizar

$$h(a) = \sum_{k=1}^n \left( \frac{x_k - a}{\sigma} \right)^2.$$

Derivando con respecto a  $a$ :

$$h'(a) = \frac{2}{\sigma} \sum_{k=1}^n \frac{x_k - a}{\sigma} = \frac{2}{\sigma} \left( \sum_{k=1}^n x_k - na \right).$$

Entonces, el valor donde se obtiene el máximo de  $L$  es

$$\hat{a} = \frac{\sum_{k=1}^n x_k}{n} =: \bar{x}_n.$$

Luego, el estimador de máxima verosimilitud de  $a$  es el promedio(!)

## Caso vectorial para $\theta$

- ▶ Podemos generalizar cuando  $\theta$  es un vector en vez de un parámetro.
- ▶ Además el conjunto de búsqueda no tiene necesariamente que ser  $\mathbb{R}^n$ . El conjunto se denomina  $\Theta$
- ▶ Entonces, el estimador de máxima verosimilitud es

$$\hat{\theta}_n = \arg \max_{\theta \in \Theta} \ell(\theta, x_1, \dots, x_n)$$



- ▶ Por ejemplo, si queremos estimar  $a$  y  $\sigma$  en el caso gaussiano, tenemos

$$(a, \sigma) \in \Theta = \mathbb{R} \times [0, \infty)$$

- ▶ La cuentas que hicimos son válidas, pensando que  $\ell$  es función también de  $\sigma$
- ▶ Resulta

$$(\hat{a}, \hat{\sigma}) = \arg \max_{\Theta} \left[ n \log \left( \frac{1}{\sigma \sqrt{2\pi}} \right) - \frac{1}{2} \sum_{k=1}^n \left( \frac{x_k - a}{\sigma} \right)^2 \right]$$

- ▶ Las cuentas van en un ejercicio del práctico 5.