

Estimación puntual de parámetros.

Parámetro (θ): Característica de la población.

En estadística la forma funcional de $f(x; \theta)$ es conocida pero se desconoce θ total o parcialmente. La estimación del parámetro ($\hat{\theta}$) debe ser función de los datos de la muestra x_1, x_2, \dots, x_n , es decir $\hat{\theta} = f(x_1, x_2, \dots, x_n)$, pero los datos x_i son cantidades aleatorias por lo tanto $\hat{\theta}$ es aleatorio, entonces debe tener sentido preguntarse por la distribución de $\hat{\theta}$ y esta distribución debe describir por completo las propiedades del estimador.

Las propiedades más deseables de los estimadores son:

- Nos gustaría que la distribución de un estimador esté centrada en el parámetro que se desea estimar. Si la media de la distribución de un estimador $\hat{\theta}$ es igual al parámetro estimado θ , se dice que el estimador está insesgado. Si no es así, se dice que el estimador está sesgado.
- Además nos gustaría que la distribución de un estimador tuviera varianza mínima; es decir, que la dispersión de la distribución fuera lo más pequeña posible, de modo que las estimaciones tiendan a ser cercanas a θ .

Definición:

Un estimador $\hat{\theta}$ de un parámetro θ es insesgado si $E(\hat{\theta}) = \theta$. Si $E(\hat{\theta}) \neq \theta$, se dice que el estimador está sesgado.

El sesgo B de un estimador $\hat{\theta}$ es igual a: $B = E(\hat{\theta}) - \theta$

Un estimador insesgado que tiene la varianza más pequeña de todos los estimadores insesgados se denomina: estimador insesgado de varianza mínima (MVUE).

Hay ocasiones en las que no podemos lograr la falta de sesgo y también la varianza mínima en el mismo estimador. En un caso así, preferimos el estimador que minimiza el error cuadrado medio (ECM):

$$ECM = E\left[(\hat{\theta} - \theta)^2\right] = V(\hat{\theta}) + B^2$$

Por lo tanto, si $\hat{\theta}$ no está sesgado, es decir, si $B = 0$, entonces $ECM = V(\hat{\theta})$.

Si $\hat{\theta}_1$ y $\hat{\theta}_2$ son estimadores de θ se dice que $\hat{\theta}_1$ es más eficiente que $\hat{\theta}_2$ si y sólo si $ECM(\hat{\theta}_1) \leq ECM(\hat{\theta}_2)$, si son insesgados: $V(\hat{\theta}_1) \leq V(\hat{\theta}_2)$

- Consistencia. Se dice que $\hat{\theta}$ (estimador de θ) es consistente si $\lim_{n \rightarrow \infty} P\left[|\hat{\theta}_n - \theta| < \varepsilon\right] \rightarrow 1$

La “distancia” entre el estimador y el parámetro debe ser pequeña; para n muy grande $\hat{\theta} \approx \theta$.

Ejemplo: Sea x_1, x_2, \dots, x_n una m.a. de n observaciones. Se desconoce la distribución de la población muestreada. Demuestre que la varianza de la muestra, s^2 , es un estimador insesgado de la varianza de la población, σ^2 .

Por la definición de la varianza de la muestra tenemos que:

$$s^2 = \frac{1}{n-1} \left[\sum_{i=1}^n x_i^2 - \frac{\left(\sum_{i=1}^n x_i \right)^2}{n} \right] = \frac{1}{n-1} \left[\sum_{i=1}^n x_i^2 - n(\bar{x})^2 \right]$$

$$\Rightarrow E(s^2) = E \left\{ \frac{1}{n-1} \left[\sum_{i=1}^n x_i^2 - n(\bar{x})^2 \right] \right\}$$

$$= \frac{1}{n-1} \left\{ E \left[\sum_{i=1}^n x_i^2 \right] - E \left[n(\bar{x})^2 \right] \right\} = \frac{1}{n-1} \left\{ \sum_{i=1}^n E(x_i^2) - nE(\bar{x}^2) \right\}$$

► Conocemos que:

$$V(X) = E(X^2) - (E(X))^2 \Rightarrow \sigma^2 = E(x^2) - \mu^2 \Rightarrow E(x^2) = \sigma^2 + \mu^2$$

Como cada x_i ($i = 1, 2, \dots, n$) se escogió al azar de una población con media μ y varianza σ^2 , por lo que: $E(x_i^2) = \sigma^2 + \mu^2$. Además $E(\bar{x}^2) = \sigma_{\bar{x}}^2 + (\mu_{\bar{x}})^2$, pero por el Teorema Central del Límite, sabemos que:

$$\bar{x} \sim N \left(\mu, \frac{\sigma^2}{n} \right)$$

$$\text{Entonces: } E(\bar{x}^2) = \sigma_{\bar{x}}^2 + (\mu_{\bar{x}})^2 = \frac{\sigma^2}{n} + \mu^2$$

$$\Rightarrow E(s^2) = \frac{1}{n-1} \left\{ \sum_{i=1}^n E(x_i^2) - nE(\bar{x}^2) \right\} = \frac{1}{n-1} \left\{ \sum_{i=1}^n (\sigma^2 + \mu^2) - n \left(\frac{\sigma^2}{n} + \mu^2 \right) \right\}$$

$$= \frac{1}{n-1} \left\{ (n\sigma^2 + n\mu^2) - \sigma^2 - n\mu^2 \right\} = \frac{1}{n-1} (n\sigma^2 - \sigma^2) = \frac{1}{n-1} (n-1)\sigma^2 = \sigma^2$$

$$\Rightarrow E(s^2) = \sigma^2$$

Por lo tanto s^2 es un estimador insesgado de σ^2 .

Ejemplo: Sea x_1, x_2, \dots, x_n variables aleatorias, $x_i \sim N(\mu, \sigma^2)$. Queremos estimar μ .

Sean $\hat{\mu}_1 = \sum_{i=1}^3 \frac{y_i}{3}$, $\hat{\mu}_2 = \frac{y_1}{2} + \frac{y_2}{3} + \frac{y_3}{6}$, $\hat{\mu}_3 = y_2$, cuál dará la mejor estimación.

➤ ¿son insesgados?

$$E(\hat{\mu}_1) = E\left(\sum_{i=1}^3 \frac{y_i}{3}\right) = \frac{1}{3} \sum_{i=1}^3 E(y_i) = \frac{1}{3} \sum_{i=1}^3 \mu = \frac{1}{3}(3\mu) = \mu \Rightarrow E(\hat{\mu}_1) = \mu$$

$$E(\hat{\mu}_2) = E\left(\frac{y_1}{2} + \frac{y_2}{3} + \frac{y_3}{6}\right) = \frac{E(y_1)}{2} + \frac{E(y_2)}{3} + \frac{E(y_3)}{6} = \frac{\mu}{2} + \frac{\mu}{3} + \frac{\mu}{6} = \frac{(3+2+1)\mu}{6} = \mu \Rightarrow E(\hat{\mu}_2) = \mu$$

$$E(\hat{\mu}_3) = E(y_2) = \mu \Rightarrow E(\hat{\mu}_3) = \mu$$

Los tres estimadores son insesgados

➤ ¿Cuál tiene la menor varianza?

$$V(\hat{\mu}_1) = V\left(\sum_{i=1}^3 \frac{y_i}{3}\right) = \frac{1}{9} \sum_{i=1}^3 V(y_i) = \frac{1}{9} \sum_{i=1}^3 \sigma^2 = \frac{1}{9}(3\sigma^2) = \frac{1}{3}\sigma^2$$

$$V(\hat{\mu}_2) = V\left(\frac{y_1}{2} + \frac{y_2}{3} + \frac{y_3}{6}\right) = \frac{\sigma^2}{4} + \frac{\sigma^2}{9} + \frac{\sigma^2}{36} = \frac{(9+4+1)\sigma^2}{36} = \frac{7}{18}\sigma^2$$

$$V(\hat{\mu}_3) = V(y_2) = \sigma^2$$

El de menor varianza es $\hat{\mu}_1 = \sum_{i=1}^3 \frac{y_i}{3} \Rightarrow \hat{\mu}_1$ es el mejor estimador.

¿Cómo estimar θ ?

- No existe una única manera de estimar un parámetro.
- No existe un único estimador de un parámetro $\Rightarrow \exists$ un mejor estimador.
- Las principales técnicas de estimación son: $\begin{cases} \text{por momentos} \\ \text{por máxima verosimilitud} \end{cases}$

Máxima verosimilitud.

Si seleccionamos al azar una muestra de n observaciones independientes e idénticamente distribuidas x_1, x_2, \dots, x_n de una v.a. x , y si la función de densidad $f(x; \theta)$ es función de un sólo parámetro θ entonces la función de densidad conjunta de los valores x_1, x_2, \dots, x_n es:

$$\underbrace{f(x_1, x_2, \dots, x_n; \theta) = f(x_1) \cdot f(x_2) \cdots f(x_n)}_{\text{verosimilitud}} \equiv L$$
$$\Rightarrow L = \prod_{i=1}^n f(x_i; \theta)$$

Fisher sugirió que se debería escoger como estimación de θ el valor que maximiza L , es decir, debemos encontrar el valor de θ que maximice la observación de la muestra conjunta x_1, x_2, \dots, x_n .

Si la verosimilitud L de la muestra es función de dos parámetros θ_1 y θ_2 entonces las estimaciones de máxima verosimilitud de θ_1 y θ_2 son los valores que maximizan L .

Suponiendo que L es función de un sólo parámetro θ , entonces el valor de θ que maximiza la verosimilitud es el valor para el cual $\frac{dL}{d\theta} = 0$, esta derivada en ocasiones puede ser difícil de obtener, ya que L es el producto de varias cantidades que dependen de θ ; por lo tanto se usa el hecho de que la función logaritmo es una función monótonamente creciente, entonces: L será máxima con el mismo valor de θ que maximiza su logaritmo. Por lo que el valor de θ que maximiza la verosimilitud será el valor para el cual $\frac{d \log L}{d\theta} = 0$

Ojo.

L será función sólo de θ , los valores de x_i se fijan y lo que importa es el recorrido del parámetro θ ; por lo que no importa que si x_i son v.a. discretas, podemos derivar libremente.

Ejemplo: Sea x_1, x_2, \dots, x_n una m.a. de n observaciones de la variable aleatoria x con función de densidad exponencial:

$$f(x; \beta) = \begin{cases} \frac{e^{-x/\beta}}{\beta} & \text{si } 0 \leq x < \infty \\ 0 & \text{en los demás puntos} \end{cases}$$

Determine el estimador de máxima verosimilitud (MLE) del parámetro β .

$$L = \prod_{i=1}^n f(x_i; \theta) = f(x_1) \cdot f(x_2) \cdots f(x_n) = \left(\frac{e^{-x_1/\beta}}{\beta} \right) \cdot \left(\frac{e^{-x_2/\beta}}{\beta} \right) \cdots \left(\frac{e^{-x_n/\beta}}{\beta} \right) = \frac{e^{-\sum x_i/\beta}}{\beta^n}$$

$$\Rightarrow \log L = \log \left(e^{-\sum x_i/\beta} \right) - n \log \beta = -\frac{\sum x_i}{\beta} - n \log \beta$$

$$\frac{d \log L}{d\beta} = \frac{\sum x_i}{\beta^2} - \frac{n}{\beta} = 0 \Rightarrow n\hat{\beta} = \sum x_i \Rightarrow \hat{\beta} = \frac{\sum_{i=1}^n x_i}{n} = \bar{x}$$

¿es máximo?

$$\left. \frac{d^2 \log L}{d\beta^2} \right|_{\beta \rightarrow \hat{\beta}} = -2 \frac{\sum x_i}{\hat{\beta}^3} + \frac{n}{\hat{\beta}^2} = -2 \frac{\sum x_i}{\left(\frac{\sum x_i}{n} \right)^3} + \frac{n}{\left(\frac{\sum x_i}{n} \right)^2} = -2 \frac{n^3}{(\sum x_i)^2} + \frac{n^3}{(\sum x_i)^2} = -\frac{n^3}{(\sum x_i)^2} < 0 \text{ (máximo)}$$

$\therefore \hat{\beta} = \bar{x}$ es el MLE de β

Ejemplo: Sea x_1, x_2, \dots, x_n una m.a. de n observaciones de la variable aleatoria x con función de densidad normal con media μ y varianza σ^2 , obtenga los MLEs de μ y σ^2 :

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

$$\begin{aligned} L &= \prod_{i=1}^n f(x_i; \theta) = f(x_1) \cdot f(x_2) \cdots f(x_n) = \\ &= \left(\frac{1}{\sqrt{2\pi\sigma^2}} \exp \left\{ -\frac{(x_1-\mu)^2}{2\sigma^2} \right\} \right) \cdot \left(\frac{1}{\sqrt{2\pi\sigma^2}} \exp \left\{ -\frac{(x_2-\mu)^2}{2\sigma^2} \right\} \right) \cdots \left(\frac{1}{\sqrt{2\pi\sigma^2}} \exp \left\{ -\frac{(x_n-\mu)^2}{2\sigma^2} \right\} \right) \\ &= \frac{\exp \left\{ -\sum \frac{(x_i-\mu)^2}{2\sigma^2} \right\}}{\sigma^n (2\pi)^{n/2}} = \left(\sigma^{-n/2} (2\pi)^{-n/2} \right) \exp \left\{ -\sum \frac{(x_i-\mu)^2}{2\sigma^2} \right\} \\ &\Rightarrow \log L = -\frac{n}{2} \log(\sigma^2) - \frac{n}{2} \log 2\pi - \frac{\sum (x_i-\mu)^2}{2\sigma^2} \end{aligned}$$

- $\frac{d \log L}{d\mu} = \frac{\sum 2(x_i - \mu)}{2\sigma^2} = 0 \Rightarrow \sum (x_i - \hat{\mu}) = 0 \Rightarrow \sum x_i - n\hat{\mu} = 0 \Rightarrow n\hat{\mu} = \sum x_i \Rightarrow \hat{\mu} = \frac{\sum x_i}{n} = \bar{x}$

- $\frac{d \log L}{d\sigma^2} = \frac{\sum (x_i - \mu)^2}{2(\sigma^2)^2} - \frac{n}{2} \left(\frac{1}{\sigma^2} \right) = 0 \Rightarrow \frac{\sum (x_i - \hat{\mu})^2}{2(\hat{\sigma}^2)^2} = \frac{n}{2} \left(\frac{1}{\hat{\sigma}^2} \right) \Rightarrow \frac{\sum (x_i - \bar{x})^2}{\hat{\sigma}^2} = n$
 $\Rightarrow \hat{\sigma}^2 = \frac{\sum (x_i - \bar{x})^2}{n}$

sesgado

$\therefore \hat{\mu} = \bar{x}$, $\hat{\sigma}^2 = \frac{\sum (x_i - \bar{x})^2}{n}$ son los MLEs de μ y σ^2

Ejemplo: Sea x_1, x_2, \dots, x_n una m.a. de n observaciones de la variable aleatoria x con función de probabilidad Bernoulli:

$$f(x; p) = p^x (1-p)^{1-x} \quad x = 0, 1$$

Determine el estimador de máxima verosimilitud (MLE) del parámetro p .

$$L = \prod_{i=1}^n f(x_i; \theta) = \prod_{i=1}^n p^{x_i} (1-p)^{1-x_i} = p^{\sum x_i} (1-p)^{\sum 1-x_i} = p^{\sum x_i} (1-p)^{(n-\sum x_i)}$$

$$\Rightarrow \log L = \sum x_i \log p + (n - \sum x_i) \log(1-p)$$

- $\frac{d \log L}{dp} = \frac{\sum x_i}{p} - \frac{(n - \sum x_i)}{1-p} = 0 \Rightarrow \frac{\sum x_i}{\hat{p}} = \frac{(n - \sum x_i)}{1-\hat{p}} \Rightarrow \frac{1-\hat{p}}{\hat{p}} = \frac{(n - \sum x_i)}{\sum x_i}$

$$\Rightarrow \frac{1}{\hat{p}} - 1 = \frac{n}{\sum x_i} - 1 \Rightarrow \hat{p} = \frac{\sum x_i}{n} \text{ proporción}$$

\therefore la proporción $\hat{p} = \frac{\sum x_i}{n}$ es el MLE de p .

Problema: ¿cómo garantizar que dentro de los estimadores $\{\hat{\theta}_i\}$ de una característica de la población se tiene “el mejor” en algún sentido?

⊕ **Cota inferior de Cramér- Rao.**

Sea x_1, x_2, \dots, x_n m.a. con $f(\cdot, \theta)$. Sea $\hat{\tau}(\theta) = T = t(x_1, x_2, \dots, x_n)$ un estimador insesgado de $\tau(\theta)$. Entonces si se cumplen los siguientes supuestos, llamados condiciones de regularidad

$$i) \frac{\partial}{\partial \theta} \log f(x; \theta) \exists \forall x \text{ y } \forall \theta$$

$$ii) \frac{\partial}{\partial \theta} \int \int \dots \int \prod_{i=1}^n f(x_i; \theta) dx_1 dx_2 \dots dx_n = \int \int \dots \int \frac{\partial}{\partial \theta} \prod_{i=1}^n f(x_i; \theta) dx_1 dx_2 \dots dx_n$$

iii)

$$\frac{\partial}{\partial \theta} \int \int \dots \int t(x_1, x_2, \dots, x_n) \prod_{i=1}^n f(x_i; \theta) dx_1 dx_2 \dots dx_n = \int \int \dots \int t(x_1, x_2, \dots, x_n) \frac{\partial}{\partial \theta} \prod_{i=1}^n f(x_i; \theta) dx_1 dx_2 \dots dx_n$$

$$iv) 0 < E \left\{ \left(\frac{\partial}{\partial \theta} \log f(x; \theta) \right)^2 \right\} < \infty \forall \theta$$

tenemos que:
$$V[T = t(x_1, x_2, \dots, x_n)] \geq \frac{[\tau'(\theta)]^2}{nE \left[\left(\frac{\partial}{\partial \theta} \log f(x; \theta) \right)^2 \right]}$$

cota inferior para la varianza de un estimador insesgado de una característica.

- Proporciona el valor mínimo que puede tomar la varianza de un estimador insesgado.
- Si tenemos varios estimadores insesgados, entonces el que tenga la varianza más cercana a esta cota será el mejor de ellos.
- Si tenemos un estimador cuya varianza alcanza la cota: este es el mejor estimador de todos.

Demostración:

$$L = \prod_{i=1}^n f(x_i; \theta) \Rightarrow \log L = \sum_{i=1}^n \log f(x_i; \theta)$$

$$\Rightarrow \frac{\partial}{\partial \theta} \log L = \sum_{i=1}^n \frac{\partial}{\partial \theta} \log f(x_i; \theta) \equiv U \text{ función score (de puntajes)}$$

$$\begin{aligned} \bullet E \left(\frac{\partial}{\partial \theta} \log f(x; \theta) \right) &= \int_{-\infty}^{\infty} \frac{\partial}{\partial \theta} \log f(x; \theta) \cdot f(x; \theta) dx = \int_{-\infty}^{\infty} \frac{\frac{\partial}{\partial \theta} f(x; \theta)}{f(x; \theta)} f(x; \theta) dx = \int_{-\infty}^{\infty} \frac{\partial}{\partial \theta} f(x; \theta) dx = \\ &= \underset{\text{condición(ii)}}{\frac{\partial}{\partial \theta} \int_{-\infty}^{\infty} f(x; \theta) dx} = \frac{\partial}{\partial \theta} (1) = 0 \end{aligned}$$

$$\therefore E \left(\frac{\partial}{\partial \theta} \log f(x; \theta) \right) = 0 \Rightarrow E(U) = E \left(\sum_{i=1}^n \frac{\partial}{\partial \theta} \log f(x_i; \theta) \right) = \sum_{i=1}^n E \left(\frac{\partial}{\partial \theta} \log f(x_i; \theta) \right) = 0$$

$$\Rightarrow E(U) = 0$$

- $E(U^2) = E\left\{\left(\sum_{i=1}^n \left(\frac{\partial}{\partial \theta} \log f(x_i; \theta)\right)^2\right)\right\}$ como las x_i son v.a.i.i.d.
 $\Rightarrow E(U^2) = E\left\{\left(\sum_{i=1}^n \left(\frac{\partial}{\partial \theta} \log f(x_i; \theta)\right)^2\right)\right\} = nE\left\{\left(\frac{\partial}{\partial \theta} \log f(x_i; \theta)\right)^2\right\}$

Pero $V(X) = E(X^2) - (E(X))^2 \Rightarrow V(U) = E(U^2) - (\cancel{E(U)})^2 = E(U^2)$

$$\therefore \underbrace{V(U) = E(U^2) = nE\left\{\left(\frac{\partial}{\partial \theta} \log f(x_i; \theta)\right)^2\right\}}_{\text{información de Fisher}} \dots (*)$$

Ahora por insesgamiento de $\hat{\tau}(\theta) = T = t(x_1, x_2, \dots, x_n)$:

$$\begin{aligned} \tau(\theta) &= E(\hat{\tau}(\theta)) = \int \int \dots \int \hat{\tau}(\theta) \cdot f(x_1; \theta) \cdot f(x_2; \theta) \dots f(x_n; \theta) dx_1 dx_2 \dots dx_n = \\ &= \int \int \dots \int \hat{\tau}(\theta) \prod_{i=1}^n f(x_i; \theta) dx_1 dx_2 \dots dx_n = \int \int \dots \int \hat{\tau}(\theta) L(\theta, \underline{x}) dx_1 dx_2 \dots dx_n \end{aligned}$$

$$\begin{aligned} \Rightarrow \tau'(\theta) &= \frac{\partial}{\partial \theta} \int \int \dots \int \hat{\tau}(\theta) L(\theta, \underline{x}) dx_1 dx_2 \dots dx_n \stackrel{\text{condición (iii)}}{=} \int \int \dots \int \hat{\tau}(\theta) \frac{\partial}{\partial \theta} L(\theta, \underline{x}) dx_1 dx_2 \dots dx_n \\ &= \int \int \dots \int \hat{\tau}(\theta) \underbrace{\frac{\partial}{\partial \theta} (\log L(\theta, \underline{x}))}_{U} \cdot L(\theta, \underline{x}) dx_1 dx_2 \dots dx_n \\ &= \int \int \dots \int \hat{\tau}(\theta) \cdot U \prod_{i=1}^n f(x_i; \theta) dx_1 dx_2 \dots dx_n = E(\hat{\tau}(\theta) \cdot U) \end{aligned}$$

$$\Rightarrow (\tau'(\theta))^2 = E^2(\hat{\tau}(\theta) \cdot U)$$

Ahora bien $Cov(X, Y) = E(X \cdot Y) - E(X)E(Y)$

Si $X = \hat{\tau}(\theta), Y = U$, tenemos:

$$Cov(\hat{\tau}(\theta), U) = E(\hat{\tau}(\theta) \cdot U) - E(\hat{\tau}(\theta)) \cancel{E(U)} \Rightarrow Cov^2(\hat{\tau}(\theta), U) = E^2(\hat{\tau}(\theta) \cdot U) = (\tau'(\theta))^2 \dots (**)$$

Por otra parte, sabemos que para v.a.: $Cov^2(X, Y) \leq V(X) \cdot V(Y)$

$$\Rightarrow Cov^2(\hat{\tau}(\theta), U) \leq V(\hat{\tau}(\theta)) \cdot V(U) \Rightarrow V(\hat{\tau}(\theta)) \geq \frac{Cov^2(\hat{\tau}(\theta), U)}{V(U)}$$

entonces, sustituyendo (*) y (**), obtenemos la **Cota inferior de Cramér- Rao (CICR)**:

$$V(\hat{\tau}(\theta)) \geq \frac{\text{Cov}^2(\hat{\tau}(\theta), U)}{V(U)} \Rightarrow V[T = t(x_1, x_2, \dots, x_n)] \geq \frac{[\tau'(\theta)]^2}{nE\left[\left(\frac{\partial}{\partial\theta} \log f(x; \theta)\right)^2\right]} \quad Q.E.D$$

$$\text{Resultado útil: } E\left[\left(\frac{\partial}{\partial\theta} \log f(x; \theta)\right)^2\right] = -E\left\{\frac{\partial^2}{\partial\theta^2} \log f(x; \theta)\right\}$$

Ejemplo: ¿Existe un estimador \hat{p} de p (distribución Bernoulli), que alcance la cota inferior de Cramér-Rao?

$$\tau(p) = p$$

$$\tau'(p) = 1$$

$$f(x; p) = p^x (1-p)^{1-x}$$

$$\log f(x; p) = x \log p + (1-x) \log(1-p)$$

$$\frac{\partial}{\partial p} \log f(x; p) = \frac{x}{p} - \frac{1-x}{1-p}$$

$$\frac{\partial^2}{\partial p^2} \log f(x; p) = -\frac{x}{p^2} - \frac{1-x}{(1-p)^2}$$

$$-E\left\{\frac{\partial^2}{\partial p^2} \log f(x; p)\right\} = E\left\{\frac{x}{p^2} + \frac{1-x}{(1-p)^2}\right\} = \frac{E(x)}{p^2} + \frac{E(1-x)}{(1-p)^2} = \frac{p}{p^2} + \frac{1-p}{(1-p)^2} = \frac{1}{p} + \frac{1}{1-p} = \frac{1}{p(1-p)}$$

$$-nE\left\{\frac{\partial^2}{\partial p^2} \log f(x; p)\right\} = \frac{n}{p(1-p)}$$

$$\Rightarrow V[\hat{p}] \geq \frac{[\tau'(p)]^2}{nE\left[\left(\frac{\partial}{\partial\theta} \log f(x; p)\right)^2\right]} = \frac{[\tau'(p)]^2}{-nE\left\{\frac{\partial^2}{\partial\theta^2} \log f(x; \theta)\right\}} = \frac{1}{\frac{n}{p(1-p)}} = \frac{p(1-p)}{n}$$

$$\Rightarrow V[\hat{p}] \geq \frac{p(1-p)}{n} \rightarrow (CICR)$$

Ya sabemos que la proporción $\hat{p} = \frac{\sum x_i}{n}$ es el MLE de p , ¿alcanza la CICR?

Primero veamos si es insesgado:

$$E(\hat{p}) = E\left(\frac{\sum x_i}{n}\right) = \frac{1}{n} \sum_{i=1}^n E(x_i) = \frac{1}{n} \sum_{i=1}^n p = \frac{np}{n} = p \Rightarrow \hat{p} \text{ es insesgado}$$

Ahora

$$V(\hat{p}) = V\left(\frac{\sum x_i}{n}\right) = \frac{1}{n^2} \sum_{i=1}^n V(x_i) = \frac{1}{n^2} \sum_{i=1}^n p(1-p) = \frac{1}{n^2} np(1-p) = \frac{p(1-p)}{n} \rightarrow \text{es la cota}$$

$\Rightarrow \hat{p}$ alcanza la CICR $\Rightarrow \hat{p}$ es el estimador de menor varianza y es el mejor estimador de todos.

Ejemplo: Normal(μ, σ^2), con μ desconocida y σ^2 conocida.

$$\tau(\mu) = \mu \Rightarrow \tau'(\mu) = 1$$

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

$$\log f(x; \mu, \sigma^2) = -\frac{1}{2} \log(2\pi\sigma^2) - \frac{(x-\mu)^2}{2\sigma^2}$$

$$\frac{\partial}{\partial \mu} \log f(x; \mu, \sigma^2) = \frac{(x-\mu)}{\sigma^2}$$

$$\frac{\partial^2}{\partial \mu^2} \log f(x; \mu, \sigma^2) = -\frac{1}{\sigma^2}$$

$$-E\left\{\frac{\partial^2}{\partial \mu^2} \log f(x; \mu, \sigma^2)\right\} = -E\left\{-\frac{1}{\sigma^2}\right\} = \frac{1}{\sigma^2}$$

$$-nE\left\{\frac{\partial^2}{\partial \mu^2} \log f(x; \mu, \sigma^2)\right\} = \frac{n}{\sigma^2}$$

$$\Rightarrow V[\hat{\mu}] \geq \frac{[\tau'(\mu)]^2}{nE\left[\left(\frac{\partial}{\partial \theta} \log f(x; \mu, \sigma^2)\right)^2\right]} = \frac{[\tau'(\mu)]^2}{-nE\left\{\frac{\partial^2}{\partial \theta^2} \log f(x; \mu, \sigma^2)\right\}} = \frac{1}{\frac{n}{\sigma^2}} = \frac{\sigma^2}{n}$$

$$\Rightarrow V[\hat{\mu}] \geq \frac{\sigma^2}{n} \rightarrow (CICR)$$

¿conocemos un estimador insesgado de μ cuya varianza sea $\frac{\sigma^2}{n}$? Si, ya que por el Teorema Central del Límite, sabemos que:

$$\bar{x} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$

es decir $V(\bar{x}) = \frac{\sigma^2}{n} \Rightarrow \hat{\mu} = \bar{x} = \frac{\sum_{i=1}^n x_i}{n}$ alcanza la CICR $\Rightarrow \bar{x}$ es MVUE.

¿Qué pasa para σ^2 desconocida?

$$\tau(\sigma^2) = \sigma^2 \Rightarrow \tau'(\sigma^2) = 1$$

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

$$\text{Sea } \sigma^2 = \theta$$

$$f(x; \mu, \theta) = \frac{1}{\sqrt{2\pi\theta}} \exp\left\{-\frac{(x-\mu)^2}{2\theta}\right\}$$

$$\log f(x; \mu, \theta) = -\frac{1}{2} \log(2\pi\theta) - \frac{(x-\mu)^2}{2\theta}$$

$$\frac{\partial}{\partial \theta} \log f(x; \mu, \theta) = -\frac{2\pi}{2(2\pi\theta)} + \frac{(x-\mu)^2}{2\theta^2} = -\frac{1}{2\theta} + \frac{(x-\mu)^2}{2\theta^2}$$

$$\frac{\partial^2}{\partial \theta^2} \log f(x; \mu, \theta) = \frac{1}{2\theta^2} + \frac{(x-\mu)^2}{\theta^3}$$

$$-E\left\{\frac{\partial^2}{\partial \theta^2} \log f(x; \mu, \theta)\right\} = -E\left\{\frac{1}{2\theta^2} + \frac{(x-\mu)^2}{\theta^3}\right\} = -\frac{1}{2\theta^2} + \frac{1}{\theta^3} E\{(x-\mu)^2\}$$

$$E\{(x-\mu)^2\} = E\{x^2 - 2x\mu + \mu^2\} = E(x^2) - 2\mu E(x) + \mu^2 = E(x^2) - 2\mu^2 + \mu^2 = E(x^2) - \mu^2$$

$$\text{Pero } V(X) = E(X^2) - (E(X))^2 \Rightarrow E(x^2) = V(x) + (E(x))^2 = \sigma^2 + \mu^2$$

$$\Rightarrow E\{(x-\mu)^2\} = E(x^2) - \mu^2 = (\sigma^2 + \mu^2) - \mu^2 = \sigma^2 = \theta$$

$$\therefore -E \left\{ \frac{\partial^2}{\partial \theta^2} \log f(x; \mu, \theta) \right\} = -\frac{1}{2\theta^2} + \frac{1}{\theta^3} \theta = -\frac{1}{2\theta^2} + \frac{1}{\theta^2} = \frac{1}{2\theta^2}$$

$$\Rightarrow -nE \left\{ \frac{\partial^2}{\partial \theta^2} \log f(x; \mu, \theta) \right\} = \frac{n}{2\theta^2}$$

$$\Rightarrow V[\hat{\theta}] \geq \frac{[\tau'(\theta)]^2}{nE \left[\left(\frac{\partial}{\partial \theta} \log f(x; \mu, \theta) \right)^2 \right]} = \frac{[\tau'(\theta)]^2}{-nE \left\{ \frac{\partial^2}{\partial \theta^2} \log f(x; \mu, \theta) \right\}} = \frac{1}{\frac{n}{2\theta^2}} = \frac{2\theta^2}{n} = \frac{2\sigma^4}{n}$$

$$\Rightarrow V[\hat{\sigma}^2] \geq \frac{2\sigma^4}{n} \rightarrow (CICR)$$

- Si μ es conocida $\hat{\sigma}^2 = \frac{\sum_{i=1}^n (x_i - \mu)^2}{n} \Rightarrow V(\hat{\sigma}^2) = \frac{2\sigma^4}{n} \Rightarrow$ alcanza la CICR

- Si μ es desconocida $\hat{\sigma}^2 = s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1} \Rightarrow V(s^2) = \frac{2\sigma^4}{n-1} \Rightarrow$ Sólo si $n \rightarrow \infty$ se alcanza la CICR

Ejemplo:

$$\text{Uniforme } (0, \theta) \Rightarrow f(x; \theta) = \frac{1}{\theta} \quad x \in (0, \theta)$$

Bajo las condiciones de regularidad ya demostramos que se debe cumplir

$$E \left(\frac{\partial}{\partial \theta} \log f(x; \theta) \right) = 0$$

Pero para la función Uniforme $(0, \theta)$ tenemos que:

$$\log f(x; \theta) = -\log \theta \Rightarrow \frac{\partial}{\partial \theta} \log f(x; \theta) = -\frac{1}{\theta}$$

$$\Rightarrow E \left(\frac{\partial}{\partial \theta} \log f(x; \theta) \right) = \int_0^\theta -\frac{1}{\theta} f(x; \theta) dx = -\int_0^\theta \frac{1}{\theta^2} dx = -\frac{1}{\theta^2} x \Big|_0^\theta = -\frac{1}{\theta^2} \theta = -\frac{1}{\theta} \neq 0$$

\therefore La función Uniforme $(0, \theta)$ no cumple las condiciones de regularidad $\Rightarrow \nexists$ CICR (No existe la cota inferior de Cramér-Rao).

Estimemos el parámetro θ , para la Uniforme $(0, \theta)$, usando la técnica de momentos y la de máxima verosimilitud:

Momentos	Máxima verosimilitud
$E(x^m) = \frac{1}{n} \sum x_i^m$ $m = 1$ $E(x) = \frac{1}{n} \sum x_i \Rightarrow \frac{\theta}{2} = \bar{x}$ $\Rightarrow \hat{\theta}_M = 2\bar{x}$	$L = \prod_{i=1}^n \frac{1}{\theta} = \frac{1}{\theta^n} \Rightarrow \log L = -n \log \theta$ $\frac{\partial}{\partial \theta} \log L = -\frac{n}{\theta} = 0!!!$ <p>no podemos maximizar $\log L$, pero si L, obsérvese que $\frac{1}{\theta^n}$ es una función decreciente de θ. Pero debe ocurrir que $\theta \geq x_i, \forall x_i$ en particular $\theta \geq x_{(n)}$ (máximo de la muestra).</p> $\Rightarrow \frac{1}{\theta} \leq \frac{1}{x_{(n)}} \Rightarrow \frac{1}{\theta^n} \leq \frac{1}{x_{(n)}^n} \Rightarrow \hat{\theta}_{MV} = x_{(n)} \text{ (MLE)}$

cuál de los dos estimadores es “el mejor”

✦ ¿son insesgados?

$$E(\hat{\theta}_M) = E(2\bar{x}) = 2E\left(\frac{\sum x_i}{n}\right) = 2 \frac{\sum E(x_i)}{n} = 2 \frac{\sum \frac{\theta}{2}}{n} = 2 \frac{n \frac{\theta}{2}}{n} = \theta \rightarrow \hat{\theta}_M \text{ es insesgado.}$$

Ahora para determinar la esperanza del estimador máximo verosímil, primero necesito conocer la función de densidad de $x_{(n)}$:

$$f_{(n)}(x) = n \left(\frac{x}{\theta}\right)^{n-1} \left(\frac{1}{\theta}\right), 0 \leq x \leq \theta$$

Entonces,

$$E(\hat{\theta}_{MV}) = E(x_{(n)}) = \int_0^{\theta} x f_{(n)}(x) dx = \int_0^{\theta} x n \left(\frac{x}{\theta}\right)^{n-1} \left(\frac{1}{\theta}\right) dx = \int_0^{\theta} n \left(\frac{x}{\theta}\right)^{n-1} \left(\frac{x}{\theta}\right) dx = \int_0^{\theta} n \left(\frac{x}{\theta}\right)^n dx$$

$$= \left(\frac{n}{\theta^n}\right) \int_0^{\theta} x^n dx = \left(\frac{n}{\theta^n}\right) \frac{x^{n+1}}{n+1} \Big|_0^{\theta} = \left(\frac{n}{\theta^n}\right) \frac{\theta^{n+1}}{n+1} = \frac{n\theta}{n+1} \rightarrow \hat{\theta}_{MV} \text{ es sesgado}$$

Aunque el estimador $\hat{\theta}_{MV}$ es sesgado observamos que fácilmente podemos obtener el estimador insesgado: $\hat{\theta}_{MV} = \frac{n+1}{n} x_{(n)} \rightarrow$ es insesgado

Por lo que ya tenemos dos estimadores insesgados $\hat{\theta}_M = 2\bar{x}$ y $\hat{\theta}_{MV} = \frac{n+1}{n} x_{(n)}$

✦ ¿Cuál tiene la menor varianza?

$$V(\hat{\theta}_M) = V(2\bar{x}) = 4V\left(\frac{\sum x_i}{n}\right) = \frac{4}{n^2} \sum V(x_i) = \frac{4}{n^2} \sum \frac{\theta^2}{12} = \frac{4n\theta^2}{12n^2} = \frac{\theta^2}{3n}$$

$$V(\hat{\theta}_{MV}) = V\left(\frac{n+1}{n} x_{(n)}\right) = \left(\frac{n+1}{n}\right)^2 V(x_{(n)}) = \left(\frac{n+1}{n}\right)^2 \left[E(x_{(n)}^2) - (E(x_{(n)}))^2 \right]$$

$$\text{Pero ya determinamos } E(x_{(n)}) = \frac{n\theta}{n+1}$$

Y además:

$$\begin{aligned} E(x_{(n)}^2) &= \int_0^{\theta} x^2 f_{(n)}(x) dx = \int_{-\infty}^{\infty} x^2 n \left(\frac{x}{\theta}\right)^{n-1} \left(\frac{1}{\theta}\right) dx = \int_0^{\theta} nx \left(\frac{x}{\theta}\right)^n dx \\ &= \left(\frac{n}{\theta^n}\right) \int_0^{\theta} x^{n+1} dx = \left(\frac{n}{\theta^n}\right) \frac{x^{n+2}}{n+2} \Big|_0^{\theta} = \left(\frac{n}{\theta^n}\right) \frac{\theta^{n+2}}{n+2} = \frac{n\theta^2}{n+2} \end{aligned}$$

$$\begin{aligned} \therefore V(\hat{\theta}_{MV}) &= \left(\frac{n+1}{n}\right)^2 \left[E(x_{(n)}^2) - (E(x_{(n)}))^2 \right] = \left(\frac{n+1}{n}\right)^2 \left[\frac{n\theta^2}{n+2} - \left(\frac{n\theta}{n+1}\right)^2 \right] = \\ &= \frac{(n+1)^2}{n^2} \left(\frac{n\theta^2}{n+2} \right) - \frac{(n+1)^2}{n^2} \left(\frac{n\theta}{n+1} \right)^2 = \frac{(n+1)^2 \theta^2}{n(n+2)} - \theta^2 = \left(\frac{(n+1)^2}{n(n+2)} - 1 \right) \theta^2 = \\ &= \left(\frac{(n+1)^2}{n(n+2)} - 1 \right) \theta^2 = \left(\frac{(n^2 + 2n + 1) - n^2 - 2n}{n(n+2)} \right) \theta^2 = \frac{\theta^2}{n(n+2)} \end{aligned}$$

Entonces tenemos que:

$$V(\hat{\theta}_M) = \frac{\theta^2}{3n} \text{ y } V(\hat{\theta}_{MV}) = \frac{\theta^2}{n(n+2)} \text{ por lo que el de menor varianza es el estimador máximo}$$

verosímil $\hat{\theta}_{MV}$

$\Rightarrow \hat{\theta}_{MV} = \frac{n+1}{n} x_{(n)}$ es mejor estimador para la función Uniforme(0, θ), aunque no existe la cota inferior de Cramér-Rao.

Estadísticas suficientes.

Habíamos definido una estadística $T = t(x_1, x_2, \dots, x_n)$, como una medida descriptiva numérica calculada a partir de datos de la muestra. Una estadística condensa o reduce las n v.a. en una v.a., por lo que debemos preguntarnos si ¿lo mismo que “decían” n v.a. sobre θ , lo dice ahora $T = t(x_1, x_2, \dots, x_n)$? ¿habremos perdido información en esta “reducción”?

Estadística suficiente. Sean x_1, x_2, \dots, x_n una m.a. de una densidad $f(\cdot; \theta)$. Una estadística $T = t(x_1, x_2, \dots, x_n)$ es suficiente para θ si y sólo si, la distribución condicional de x_1, x_2, \dots, x_n dado $T = t_i$ no depende de θ para ningún valor t_i de T .

- Basta conocer los valores de la estadística suficiente T para conocer θ .
- “Lo demás que no sea T ” no aporta información sobre θ .
- T (una estadística suficiente) “condensa o reduce” el rango de valores de una manera que no haya pérdida de información sobre θ .

Ejemplo:

Sean x_1, x_2, x_3 tres ensayos Bernoulli $f(x; p) = p^x (1-p)^{1-x}$ $x = 0, 1$ y $T = t(x_1, x_2, x_3) = (x_1 \cdot x_2) + x_3$ una estadística.

Sea ω el rango de valores de la tripleta (x_1, x_2, x_3) : $\omega = \left\{ \begin{array}{l} (0, 0, 0), (0, 0, 1), (0, 1, 0), (1, 0, 0) \\ (1, 1, 1), (0, 1, 1), (1, 0, 1), (1, 1, 0) \end{array} \right\}$

$$T = t(x_1, x_2, x_3) = (x_1 \cdot x_2) + x_3 = \begin{cases} 0 & (x_1, x_2, x_3) = (0, 0, 0), (1, 0, 0), (0, 1, 0) \\ 1 & (1, 1, 0), (0, 0, 1), (0, 1, 1), (1, 0, 1) \\ 2 & (1, 1, 1) \end{cases}$$

La distribución condicional de x_1, x_2, x_3 dado $T = t$, será:

$$P(X_1 = x_1, X_2 = x_2, X_3 = x_3 | T = t) = \frac{P(X_1 = x_1, X_2 = x_2, X_3 = x_3)}{P(T = t)}$$

Para $T = 0$: tomando la tripleta $(0, 0, 0)$

$$\begin{aligned}
P(X_1 = 0, X_2 = 0, X_3 = 0 | T = 0) &= \frac{P(X_1 = 0, X_2 = 0, X_3 = 0)}{P(T = 0)} = \frac{P(X_1 = 0) \cdot P(X_2 = 0) \cdot P(X_3 = 0)}{P(T = 0)} = \\
&= \frac{(1-p)^3}{(1-p)^3 + p(1-p)^2 + p(1-p)^2} = \frac{(1-p)^3}{(1-p)^3 + 2p(1-p)^2} = \frac{1}{1 + \frac{2p}{(1-p)}}
\end{aligned}$$

depende de p, por lo tanto $T = t(x_1, x_2, x_3) = (x_1 \cdot x_2) + x_3$ no es una estadística suficiente para p, lo que indica que se ha perdido información.

Ejemplo: Para x_1, x_2, \dots, x_n una m.a. de n observaciones de la variable aleatoria x con función de probabilidad Bernoulli:

$$f(x; p) = p^x (1-p)^{1-x} \quad x = 0, 1$$

Sabemos que el estimador de máxima verosimilitud del parámetro p, es $\hat{p} = \frac{\sum x_i}{n}$, ¿será

$T = t = \sum x_i$ una estadística suficiente para p?

Tenemos que: $x_i \sim \text{Bernoulli}(p) \Rightarrow t = \sum x_i \sim \text{Binomial}(n, p)$, por lo tanto, la distribución condicional de x_1, x_2, x_3 dado $T = t = \sum x_i$, será

$$\begin{aligned}
P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n | T = \sum x_i = t) &= \frac{P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n)}{P(T = \sum x_i = t)} = \frac{\prod_{i=1}^n p^{x_i} (1-p)^{1-x_i}}{\binom{n}{t} p^t (1-p)^{n-t}} = \\
&= \frac{p^{\sum x_i} (1-p)^{n-\sum x_i}}{\binom{n}{t} p^t (1-p)^{n-t}} = \frac{p^t (1-p)^{n-t}}{\binom{n}{t} p^t (1-p)^{n-t}} = \frac{1}{\binom{n}{t}} \rightarrow \text{no depende de } p \Rightarrow T = \sum x_i \text{ es suficiente para } p
\end{aligned}$$

$\therefore \hat{p} = \frac{\sum x_i}{n}$ es una función 1 a 1 de la estadística suficiente, no hay perdida de información sobre p.

Estadísticas conjuntamente suficientes. Sea x_1, x_2, \dots, x_n una m.a. de densidad $f(\cdot; \theta)$. Las estadísticas S_1, S_2, \dots, S_k son conjuntamente suficientes, si la distribución condicional de x_1, x_2, \dots, x_n dado $S_1 = s_1, S_2 = s_2, \dots, S_k = s_k$ no dependen de θ .

¿Habrá una forma más económica de decidir si una estadística es suficiente para un parámetro θ ? \rightarrow Criterio de factorización.

Criterio de factorización. Sea x_1, x_2, \dots, x_n una m.a. de densidad $f(\cdot; \theta)$. Una estadística $S = s(x_1, x_2, \dots, x_n)$ es suficiente si y sólo si la densidad conjunta de x_1, x_2, \dots, x_n se puede factorizar como:

$$f_{\underline{x}}(x_1, x_2, \dots, x_n) = g(s(x_1, x_2, \dots, x_n); \theta) h(x_1, x_2, \dots, x_n) = g(S; \theta) h(x_1, x_2, \dots, x_n)$$

Equivalentemente, para estadísticas conjuntamente suficientes:

$$\begin{aligned} f_{\underline{x}}(x_1, x_2, \dots, x_n) &= g(s_1(x_1, x_2, \dots, x_n), s_2(x_1, x_2, \dots, x_n), \dots, s_k(x_1, x_2, \dots, x_n); \theta) h(x_1, x_2, \dots, x_n) \\ &= g(S_1, S_2, \dots, S_k; \theta) h(x_1, x_2, \dots, x_n) \end{aligned}$$

h es una función no negativa que no depende de θ

g es no negativa y depende de x_1, x_2, \dots, x_n sólo a través de $s_1(x_1, x_2, \dots, x_n), \dots, s_k(x_1, x_2, \dots, x_n)$

Ejemplo: Sea x_1, x_2, \dots, x_n una m.a. de n observaciones de la variable aleatoria x con función de probabilidad Bernoulli:

$$f(x; p) = p^x (1-p)^{1-x} \quad x = 0, 1$$

$$\Rightarrow f_{\underline{x}}(x_1, x_2, \dots, x_n) = \prod_{i=1}^n p^{x_i} (1-p)^{1-x_i} \cdot 1_{\{0,1\}}^{(x_i)} = p^{\sum x_i} (1-p)^{n-\sum x_i} \prod 1_{\{0,1\}}^{(x_i)} = g(S; p) h(x_1, x_2, \dots, x_n)$$

$$\Rightarrow \left\{ \begin{array}{l} h(x_1, x_2, \dots, x_n) = \prod 1_{\{0,1\}}^{(x_i)} \\ g(S; p) = p^{\sum x_i} (1-p)^{n-\sum x_i} \end{array} \right\} \Rightarrow S = \sum x_i \text{ es la estadística suficiente para } p.$$

Ejemplo: Sea x_1, x_2, \dots, x_n una m.a. Normal (μ, σ^2)

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

$$\begin{aligned} \Rightarrow f_{\underline{x}}(x_1, x_2, \dots, x_n) &= \prod_{i=1}^n f(x; \mu, \sigma^2) = \left(\frac{1}{2\pi}\right)^{n/2} \sigma^{-n} \exp\left\{-\frac{1}{2\sigma^2} \sum (x_i - \mu)^2\right\} = \\ &= \left(\frac{1}{2\pi}\right)^{n/2} \sigma^{-n} \exp\left\{-\frac{1}{2\sigma^2} (\sum x_i^2 - 2\mu \sum x_i + n\mu^2)\right\} = \\ &= \left(\frac{1}{2\pi}\right)^{n/2} 1_{\{0,1\}}^{(x_i)} \cdot \underbrace{\sigma^{-n} \left[\exp\left\{-\frac{1}{2\sigma^2} \sum x_i^2\right\} \exp\left\{-\frac{1}{2\sigma^2} (-2\mu \sum x_i + n\mu^2)\right\} \right]}_{g(S_1, S_2, \mu, \sigma^2)} \end{aligned}$$

$$\Rightarrow \left\{ \begin{array}{l} h(x_1, x_2, \dots, x_n) = \left(\frac{1}{2\pi}\right)^{n/2} 1_{\{0,1\}}^{(x_i)} \\ g(S_1, S_2; \mu, \sigma^2) = \sigma^{-n} \left[\exp\left\{-\frac{1}{2\sigma^2} \sum x_i^2\right\} \exp\left\{-\frac{1}{2\sigma^2} (-2\mu \sum x_i + n\mu^2)\right\} \right] \end{array} \right\} \Rightarrow S_1 = \sum x_i; S_2 = \sum x_i^2$$

$\Rightarrow (\sum x_i, \sum x_i^2)$ son conjuntamente suficientes para (μ, σ^2) y por lo tanto:

$$\hat{\mu} = \bar{x} = \frac{\sum x_i}{n} \quad \text{y} \quad \hat{\sigma}^2 = s^2 = \frac{\sum x_i^2 - \frac{(\sum x_i)^2}{n}}{n-1} \quad \text{son funciones 1 a 1 de la estadística suficiente.}$$

Un método para deducir un estadístico suficiente y minimal es el de Lehmann y Scheffé, que emplea la razón de verosimilitudes evaluadas en dos puntos (x_1, x_2, \dots, x_n) y (y_1, y_2, \dots, y_n) :

$$\frac{L(x_1, x_2, \dots, x_n; \theta)}{L(y_1, y_2, \dots, y_n; \theta)}$$

Muchas veces es posible encontrar una función $g(x_1, x_2, \dots, x_n)$ tal que esta razón no depende de θ si y sólo si $g(x_1, x_2, \dots, x_n) = g(y_1, y_2, \dots, y_n)$. si es posible encontrar dicha función entonces $g(X_1, X_2, \dots, X_n)$ es un estadístico suficiente minimal para θ .

Ejemplo: Sea x_1, x_2, \dots, x_n una m.a. de una función de probabilidad Bernoulli:

$$f(x; p) = p^x (1-p)^{1-x} \quad x = 0, 1$$

$$\frac{L(x_1, x_2, \dots, x_n; \theta)}{L(y_1, y_2, \dots, y_n; \theta)} = \frac{\prod_{i=1}^n p^{x_i} (1-p)^{1-x_i}}{\prod_{i=1}^n p^{y_i} (1-p)^{1-y_i}} = \frac{p^{\sum x_i} (1-p)^{n-\sum x_i}}{p^{\sum y_i} (1-p)^{n-\sum y_i}} = \left(\frac{p}{1-p}\right)^{\sum x_i - \sum y_i}$$

Para que esta razón no dependa de $\theta = p$, la única posibilidad es que

$$\sum x_i - \sum y_i = 0 \Rightarrow \sum x_i = \sum y_i \Rightarrow \text{Pero } g(x_1, x_2, \dots, x_n) = g(y_1, y_2, \dots, y_n)$$

$$\Rightarrow g(x_1, x_2, \dots, x_n) = \sum x_i$$

$\therefore \sum x_i$ es una estadística suficiente y minimal para p.

Familia exponencial.

Definición. Familia exponencial de k parámetros.

Una familia de densidades $f(\cdot; \theta_1, \theta_2, \dots, \theta_k)$ que puede expresarse como:

$$f(x; \theta_1, \theta_2, \dots, \theta_k) = a(\theta_1, \theta_2, \dots, \theta_k) b(x) \exp \left\{ \sum_{j=1}^k c_j(\theta_1, \theta_2, \dots, \theta_k) d_j(x) \right\}$$

se dice que pertenece a la familia exponencial.

Ejemplo: Bernoulli(θ) $\theta = 0, 1$

$$\begin{aligned} f(x; \theta) &= \theta^x (1-\theta)^{1-x} = e^{x \log \theta} e^{(1-x) \log(1-\theta)} = e^{x \log \theta} \cdot e^{\log(1-\theta)} e^{-x \log(1-\theta)} = e^{x(\log \theta - \log(1-\theta))} e^{\log(1-\theta)} \\ &= e^{x \log \left(\frac{\theta}{1-\theta} \right)} e^{\log(1-\theta)} \end{aligned}$$

Entonces, definimos:

$$\left. \begin{aligned} a(\theta) &= e^{\log(1-\theta)} \\ b(x) &= 1_{\{0,1\}}^{(x)} \\ c_1(\theta) &= \log \left(\frac{\theta}{1-\theta} \right) \\ d_1(x) &= x \end{aligned} \right\} \Rightarrow \text{la Bernoulli es de la familia exponencial}$$

Ejemplo: Poisson (θ)

$$f(x; \theta) = \frac{\theta^x e^{-\theta}}{x!} = \frac{e^{x \log \theta} e^{-\theta}}{x!}$$

Entonces, definimos:

$$\left. \begin{aligned} a(\theta) &= e^{-\theta} \\ b(x) &= \frac{1}{x!} \\ c_1(\theta) &= \log \theta \\ d_1(x) &= x \end{aligned} \right\} \Rightarrow \text{la Poisson es de la familia exponencial}$$

Ejemplo: Normal(μ, σ^2)

$$f(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(x-\mu)^2}{2\sigma^2}\right\} = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{x^2 - 2x\mu + \mu^2}{2\sigma^2}\right\}$$

$$= \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{\mu^2}{2\sigma^2}\right\} \exp\left\{\frac{\mu}{\sigma^2}x - \frac{x^2}{2\sigma^2}\right\}$$

Entonces, definimos:

$$\left. \begin{aligned} a(\mu, \sigma^2) &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{\mu^2}{2\sigma^2}\right\} \\ b(x) &= 1_{\{-\infty, \infty\}}^{(x_i)} \\ c_1(\mu, \sigma^2) &= \frac{\mu}{\sigma^2} \\ d_1(x) &= x \\ c_2(\mu, \sigma^2) &= -\frac{1}{2\sigma^2} \\ d_2(x) &= x^2 \end{aligned} \right\} \Rightarrow \text{la Normal}(\mu, \sigma^2) \text{ es de la familia exponencial}$$

Familia exponencial: Binomial, Exponencial, Beta, Gamma, Normal, χ^2 .

- **Resultado importante:** Si $f(\cdot; \theta)$ es de la familia exponencial entonces $\sum_{i=1}^n d(x_i)$ es una estadística suficiente para θ .

Algunas “cosas” sobre el estimador máximo verosímil:

- **Principio de invarianza.** Sea $\hat{\underline{\theta}} = (\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_k)$ el estimador máximo verosímil de $\underline{\theta}$. Si $\tau(\underline{\theta}) = (\tau_1(\theta_1), \tau_2(\theta_2), \dots, \tau_k(\theta_k))$ es una transformación del espacio parametral, entonces el estimador máximo verosímil de $\tau(\underline{\theta})$ es:

$$\tau(\hat{\underline{\theta}}) = (\tau_1(\hat{\theta}_1), \tau_2(\hat{\theta}_2), \dots, \tau_k(\hat{\theta}_k))$$

Ejemplo. Poisson:

$\hat{\theta} = \bar{x} \rightarrow$ *estimador máximo verosímil*

transformación : $\tau(\theta) = P(x=0) = e^{-\theta}$

$\tau(\hat{\theta}) = e^{-\hat{\theta}} = e^{-\bar{x}} \rightarrow$ *estimador máximo verosímil de la transformación*

- **Bajo condiciones de regularidad.** Un estimador máximo verosímil, que depende de n , se distribuye asintóticamente como:

$$\hat{\theta}_{MV(n)} \stackrel{a}{\sim} N \left(\theta, \frac{1}{nE \left\{ \left(\frac{\partial}{\partial \theta} \log f(x; \theta) \right)^2 \right\}} \right)$$