

# Probabilidades y Estadística

## Clase Auxiliar

Profesor: Fernando Lema  
Auxiliares: Víctor Carmi - Abelino Jiménez

Universidad de Chile

# Indice General

- 1 **Contenidos**
  - Muestras y Distribuciones muestrales
  - Estimación Puntual

# Indice General

- 1 **Contenidos**
  - Muestras y Distribuciones muestrales
  - Estimación Puntual

# Advertencias y Recomendaciones

- Tener presente siempre de qué se está hablando.
- Distinguir entre variables aleatorias, números desconocidos y valores muestrales.
- Cuidado con la Notación.

# Advertencias y Recomendaciones

- Tener presente siempre de qué se está hablando.
- Distinguir entre variables aleatorias, números desconocidos y valores muestrales.
- Cuidado con la Notación.

# Advertencias y Recomendaciones

- Tener presente siempre de qué se está hablando.
- Distinguir entre variables aleatorias, números desconocidos y valores muestrales.
- Cuidado con la Notación.

# Muestras Aleatorias

## Definición MUESTRA ALEATORIA

Sea  $X$  v.a. con cierta distribución de probabilidad. Sean  $X_1, X_2, \dots, X_n$   $n$  vs. as ind, cada una con la misma distribución de  $X$ . Se dice que  $(X_1, X_2, \dots, X_n)$  una muestra aleatoria de  $X$ .

## Definición ESTADÍSTICO

Sea  $X_1, \dots, X_n$  una muestra aleatoria de una v.a.  $X$  y sean  $x_1, \dots, x_n$  los valores tomados por la muestra. Sea  $H$  una función definida para  $(x_1, \dots, x_n)$ . Se dice que  $Y = H(X_1, \dots, X_n)$  es un estadístico que toma el valor  $y = H(x_1, \dots, x_n)$ .

## OBSERVACIONES:

- Una muestra aleatoria se puede considerar como  $n$  mediciones de la variable  $X$ .
- Un Estadístico es una variable aleatoria.

# Muestras Aleatorias

## Definición MUESTRA ALEATORIA

Sea  $X$  v.a. con cierta distribución de probabilidad. Sean  $X_1, X_2, \dots, X_n$   $n$  vs. as ind, cada una con la misma distribución de  $X$ . Se dice que  $(X_1, X_2, \dots, X_n)$  una muestra aleatoria de  $X$ .

## Definición ESTADISTICO

Sea  $X_1, \dots, X_n$  una muestra aleatoria de una v.a.  $X$  y sean  $x_1, \dots, x_n$  los valores tomados por la muestra. Sea  $H$  una función definida para  $(x_1, \dots, x_n)$ . Se dice que  $Y = H(X_1, \dots, X_n)$  es un estadístico que toma el valor  $y = H(x_1, \dots, x_n)$ .

## OBSERVACIONES:

- Una muestra aleatoria se puede considerar como  $n$  mediciones de la variable  $X$ .
- Un Estadístico es una variable aleatoria.



# Muestras Aleatorias

## Definición MUESTRA ALEATORIA

Sea  $X$  v.a. con cierta distribución de probabilidad. Sean  $X_1, X_2, \dots, X_n$   $n$  vs. as ind, cada una con la misma distribución de  $X$ . Se dice que  $(X_1, X_2, \dots, X_n)$  una muestra aleatoria de  $X$ .

## Definición ESTADISTICO

Sea  $X_1, \dots, X_n$  una muestra aleatoria de una v.a.  $X$  y sean  $x_1, \dots, x_n$  los valores tomados por la muestra. Sea  $H$  una función definida para  $(x_1, \dots, x_n)$ . Se dice que  $Y = H(X_1, \dots, X_n)$  es un estadístico que toma el valor  $y = H(x_1, \dots, x_n)$ .

## OBSERVACIONES:

- Una muestra aleatoria se puede considerar como  $n$  mediciones de la variable  $X$ .
- Un Estadístico es una variable aleatoria.

# Muestras Aleatorias

## Definición MUESTRA ALEATORIA

Sea  $X$  v.a. con cierta distribución de probabilidad. Sean  $X_1, X_2, \dots, X_n$   $n$  vs. as ind, cada una con la misma distribución de  $X$ . Se dice que  $(X_1, X_2, \dots, X_n)$  una muestra aleatoria de  $X$ .

## Definición ESTADISTICO

Sea  $X_1, \dots, X_n$  una muestra aleatoria de una v.a.  $X$  y sean  $x_1, \dots, x_n$  los valores tomados por la muestra. Sea  $H$  una función definida para  $(x_1, \dots, x_n)$ . Se dice que  $Y = H(X_1, \dots, X_n)$  es un estadístico que toma el valor  $y = H(x_1, \dots, x_n)$ .

## OBSERVACIONES:

- Una muestra aleatoria se puede considerar como  $n$  mediciones de la variable  $X$ .
- Un Estadístico es una variable aleatoria.

# Algunos Estadísticos Importantes

Sean  $(X_1, \dots, X_n)$  una muestra aleatoria de la v.a.  $X$ . Los siguientes estadísticos son de interés:

Promedio Muestral

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$$

Varianza Muestral

$$S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}$$

# Algunos Estadísticos Importantes

Sean  $(X_1, \dots, X_n)$  una muestra aleatoria de la v.a.  $X$ . Los siguientes estadísticos son de interés:

## Promedio Muestral

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$$

## Varianza Muestral

$$S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}$$

# Algunos Estadísticos Importantes

Sean  $(X_1, \dots, X_n)$  una muestra aleatoria de la v.a.  $X$ . Los siguientes estadísticos son de interés:

## Promedio Muestral

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$$

## Varianza Muestral

$$S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}$$

# Algunos Estadísticos Importantes

## Mínimo de la Muestra

$$K = \min(X_1, \dots, X_n)$$

## Máximo de la Muestra

$$M = \max(X_1, \dots, X_n)$$

## Recorrido de la Muestra

$$R = M - m$$

# Algunos Estadísticos Importantes

## Mínimo de la Muestra

$$K = \min(X_1, \dots, X_n)$$

## Máximo de la Muestra

$$M = \max(X_1, \dots, X_n)$$

## Recorrido de la Muestra

$$R = M - m$$

# Algunos Estadísticos Importantes

## Mínimo de la Muestra

$$K = \min(X_1, \dots, X_n)$$

## Máximo de la Muestra

$$M = \max(X_1, \dots, X_n)$$

## Recorrido de la Muestra

$$R = M - m$$



# Algunas Cosas Conocidas

## Teorema

Sea  $X$  una v.a. con  $E(X) = \mu$  y  $Var(X) = \sigma^2$ . Sea  $\bar{X}$  el promedio muestral de una muestra aleatoria simple de tamaño  $n$ . Entonces

(a)  $E(\bar{X}) = \mu$

(b)  $Var(\bar{X}) = \frac{\sigma^2}{n}$

(c) Para  $n$  grande,  $(\bar{X} - \mu)/(\sigma/\sqrt{n})$  tiene aproximadamente la distribución  $N(0, 1)$

OBSERVACIÓN.

(c) se aplica para  $n$  grande. De lo contrario hay que encontrar la distribución de  $\bar{X}$ .

# Algunas Cosas Conocidas

## Teorema

Sea  $X$  una v.a. con  $E(X) = \mu$  y  $Var(X) = \sigma^2$ . Sea  $\bar{X}$  el promedio muestral de una muestra aleatoria simple de tamaño  $n$ . Entonces

(a)  $E(\bar{X}) = \mu$

(b)  $Var(\bar{X}) = \frac{\sigma^2}{n}$

(c) Para  $n$  grande,  $(\bar{X} - \mu)/(\sigma/\sqrt{n})$  tiene aproximadamente la distribución  $N(0, 1)$

OBSERVACIÓN.

(c) se aplica para  $n$  grande. De lo contrario hay que encontrar la distribución de  $\bar{X}$ .

# Algunas Cosas Conocidas

## Teorema

Sea  $X$  una v.a. continua con fdp  $f$  y fda  $F$ . Sea  $X_1, \dots, X_n$  una muestra aleatoria de  $X$  y sean  $K$  y  $M$  el mínimo y el máximo de la muestra respectivamente. Luego:

(a) La fdp de  $M$  está dada por  $g(m) = n[F(m)]^{n-1} f(m)$

(b) La fdp de  $K$  está dada por  $h(k) = n[1 - F(k)]^{n-1} f(k)$

EJERCICIO PARA REPASAR.

Tomar el caso en que la distribución sea exponencial.

# Algunas Cosas Conocidas

## Teorema

Sea  $X$  una v.a. continua con fdp  $f$  y fda  $F$ . Sea  $X_1, \dots, X_n$  una muestra aleatoria de  $X$  y sean  $K$  y  $M$  el mínimo y el máximo de la muestra respectivamente. Luego:

(a) La fdp de  $M$  está dada por  $g(m) = n[F(m)]^{n-1} f(m)$

(b) La fdp de  $K$  está dada por  $h(k) = n[1 - F(k)]^{n-1} f(k)$

EJERCICIO PARA REPASAR.

Tomar el caso en que la distribución sea exponencial.

# Indice General

- 1 **Contenidos**
  - Muestras y Distribuciones muestrales
  - **Estimación Puntual**

# Definiciones Básicas

## Definición ESTIMADOR

Sea  $X$  v.a. con cierta distribución de probabilidad dependiente de un parámetro  $\theta$ . Sea  $X_1, X_2, \dots, X_n$  una muestra de  $X$  y sean  $x_1, \dots, x_n$  los valores muestrales. Si  $g(X_1, \dots, X_n)$  es una función de la muestra que va a ser usada para estimar  $\theta$ , nos referimos a  $g$  como un **estimador** de  $\theta$ . Llamaremos a  $\hat{\theta} = g(x_1, \dots, x_n)$  estimación de  $\theta$ .

OBSERVACION (ABUSO DE NOTACIÓN):

$\hat{\theta}$  v/s  $\theta$

Para nosotros  $\hat{\theta}$  es una v.a. y  $\theta$  un número desconocido.  
hablaremos de  $E(\hat{\theta})$  como  $E(g(X_1, \dots, X_n))$

# Definiciones Básicas

## Definición ESTIMADOR

Sea  $X$  v.a. con cierta distribución de probabilidad dependiente de un parámetro  $\theta$ . Sea  $X_1, X_2, \dots, X_n$  una muestra de  $X$  y sean  $x_1, \dots, x_n$  los valores muestrales. Si  $g(X_1, \dots, X_n)$  es una función de la muestra que va a ser usada para estimar  $\theta$ , nos referimos a  $g$  como un **estimador** de  $\theta$ . Llamaremos a  $\hat{\theta} = g(x_1, \dots, x_n)$  estimación de  $\theta$ .

OBSERVACION (ABUSO DE NOTACIÓN):

$\hat{\theta}$  v/s  $\theta$

Para nosotros  $\hat{\theta}$  es una v.a. y  $\theta$  un número desconocido.  
hablaremos de  $E(\hat{\theta})$  como  $E(g(X_1, \dots, X_n))$

# Definiciones Básicas

## Definición ESTIMADOR INSESGADO

Sea  $\hat{\theta}$  una estimación del parámetro desconocido  $\theta$  asociado a la distribución de la v. a.  $X$ . Entonces  $\hat{\theta}$  es un **estimador insesgado** para  $\theta$  si  $E(\hat{\theta}) = \theta$  para cualquier  $\theta$ .

## Definición ESTIMADOR DE VARIANZA MINIMA

Sea  $\hat{\theta}$  una estimación insesgada de  $\theta$ . Diremos que  $\hat{\theta}$  es una **estimación de varianza mínima** de  $\theta$  si para todas las estimaciones  $\theta^*$  tales que  $E(\theta^*) = \theta$ , tenemos  $Var(\hat{\theta}) \leq Var(\theta^*)$  para cualquier  $\theta$ .

Es decir, entre todas las estimaciones insesgadas de  $\theta$ ,  $\hat{\theta}$  tiene la varianza más pequeña.



# Definiciones Básicas

## Definición ESTIMADOR INSESGADO

Sea  $\hat{\theta}$  una estimación del parámetro desconocido  $\theta$  asociado a la distribución de la v. a.  $X$ . Entonces  $\hat{\theta}$  es un **estimador insesgado** para  $\theta$  si  $E(\hat{\theta}) = \theta$  para cualquier  $\theta$ .

## Definición ESTIMADOR DE VARIANZA MINIMA

Sea  $\hat{\theta}$  una estimación insesgada de  $\theta$ . Diremos que  $\hat{\theta}$  es una **estimación de varianza mínima** de  $\theta$  si para todas las estimaciones  $\theta^*$  tales que  $E(\theta^*) = \theta$ , tenemos  $Var(\hat{\theta}) \leq Var(\theta^*)$  para cualquier  $\theta$ .

Es decir, entre todas las estimaciones insesgadas de  $\theta$ ,  $\hat{\theta}$  tiene la varianza más pequeña.

# Definiciones Básicas

## Definición ESTIMADOR CONVERGENTE

Sea  $\hat{\theta}$  una estimación de  $\theta$ . Se dice que  $\hat{\theta}$  es una **estimación convergente** a  $\theta$  si

$$\lim_{n \rightarrow \infty} P(|\hat{\theta} - \theta| > \varepsilon) = 0 \quad \forall \varepsilon > 0$$

o equivalentemente

$$\lim_{n \rightarrow \infty} P(|\hat{\theta} - \theta| \leq \varepsilon) = 1 \quad \forall \varepsilon > 0$$

OBSERVACION:

En general, decir a partir de la definición, si el estimador es consistente es algo difícil. Para facilitar las cosas se tiene el siguiente teorema.

# Definiciones Básicas

## Definición ESTIMADOR CONVERGENTE

Sea  $\hat{\theta}$  una estimación de  $\theta$ . Se dice que  $\hat{\theta}$  es una **estimación convergente** a  $\theta$  si

$$\lim_{n \rightarrow \infty} P(|\hat{\theta} - \theta| > \varepsilon) = 0 \quad \forall \varepsilon > 0$$

o equivalentemente

$$\lim_{n \rightarrow \infty} P(|\hat{\theta} - \theta| \leq \varepsilon) = 1 \quad \forall \varepsilon > 0$$

OBSERVACION:

En general, decir a partir de la definición, si el estimador es consistente es algo difícil. Para facilitar las cosas se tiene el siguiente teorema.

# Teorema de Consistencia

## TEOREMA

Sea  $\hat{\theta}$  una estimación de  $\theta$ . Si  $\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta$  y si  $\lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}) = 0$ , entonces  $\hat{\theta}$  es una estimación convergente de  $\theta$ .

## DEMOSTRACION

Tenemos la Desigualdad de Chebyshev:

$$P(|\hat{\theta} - \theta| \geq \varepsilon) \leq \frac{1}{\varepsilon^2} E[(\hat{\theta} - \theta)^2]$$

Con el teorema anterior, se tiene inmediatamente que

## TEOREMA

Sea  $X$  v.a. con esperanza  $\mu$  y varianza  $\sigma^2$ . Sea  $\bar{X}$  el promedio muestral obtenido de una muestra de tamaño  $n$ . Entonces  $\bar{X}$  es un estimador insesgado y convergente a  $\mu$ .

# Teorema de Consistencia

## TEOREMA

Sea  $\hat{\theta}$  una estimación de  $\theta$ . Si  $\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta$  y si  $\lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}) = 0$ , entonces  $\hat{\theta}$  es una estimación convergente de  $\theta$ .

## DEMOSTRACION

Tenemos la Desigualdad de Chebyshev:

$$P(|\hat{\theta} - \theta| \geq \varepsilon) \leq \frac{1}{\varepsilon^2} E[(\hat{\theta} - \theta)^2]$$

Con el teorema anterior, se tiene inmediatamente que

## TEOREMA

Sea  $X$  v.a. con esperanza  $\mu$  y varianza  $\sigma^2$ . Sea  $\bar{X}$  el promedio muestral obtenido de una muestra de tamaño  $n$ . Entonces  $\bar{X}$  es un estimador insesgado y convergente a  $\mu$ .

# Teorema de Consistencia

## TEOREMA

Sea  $\hat{\theta}$  una estimación de  $\theta$ . Si  $\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta$  y si  $\lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}) = 0$ , entonces  $\hat{\theta}$  es una estimación convergente de  $\theta$ .

## DEMOSTRACION

Tenemos la Desigualdad de Chebyshev:

$$P(|\hat{\theta} - \theta| \geq \varepsilon) \leq \frac{1}{\varepsilon^2} E[(\hat{\theta} - \theta)^2]$$

Con el teorema anterior, se tiene inmediatamente que

## TEOREMA

Sea  $X$  v.a. con esperanza  $\mu$  y varianza  $\sigma^2$ . Sea  $\bar{X}$  el promedio muestral obtenido de una muestra de tamaño  $n$ . Entonces  $\bar{X}$  es un estimador insesgado y convergente a  $\mu$ .

# Error Cuadrático Medio

## Definición ERROR CUADRÁTICO MEDIO

Se define al **error cuadrático medio** de un estimador  $\hat{\theta}$  de  $\theta$  como

$$ECM(\hat{\theta}) = E\left((\hat{\theta} - \theta)^2\right)$$

Notemos que

$$ECM(\hat{\theta}) = \text{Var}(\hat{\theta}) + \text{Sesgo}^2$$

donde

$$\text{Sesgo} = E(\hat{\theta}) - \theta$$

# Error Cuadrático Medio

## Definición ERROR CUADRÁTICO MEDIO

Se define al **error cuadrático medio** de un estimador  $\hat{\theta}$  de  $\theta$  como

$$ECM(\hat{\theta}) = E\left((\hat{\theta} - \theta)^2\right)$$

Notemos que

$$ECM(\hat{\theta}) = \text{Var}(\hat{\theta}) + \text{Sesgo}^2$$

donde

$$\text{Sesgo} = E(\hat{\theta}) - \theta$$



## Problema

P1

Sea  $X_1, X_2, \dots, X_n$  una muestra de  $X$  tal que  $E(X) = \mu$  y  $Var(X) = \sigma^2$

Mostrar que  $E\left(\sum_{i=1}^n (X_i - \bar{X})^2\right) = (n-1) \cdot \sigma^2$

Esto genera que

$$\hat{\sigma}_{n-1}^2 = \frac{1}{n-1} \left( \sum_{i=1}^n (X_i - \bar{X})^2 \right)$$

es un estimador insesgado de  $\sigma^2$

Se denota

$$\hat{\sigma}_n^2 = \frac{1}{n} \left( \sum_{i=1}^n (X_i - \bar{X})^2 \right)$$

## Problema

P1

Sea  $X_1, X_2, \dots, X_n$  una muestra de  $X$  tal que  $E(X) = \mu$  y  $Var(X) = \sigma^2$

Mostrar que  $E\left(\sum_{i=1}^n (X_i - \bar{X})^2\right) = (n-1) \cdot \sigma^2$

Esto genera que

$$\hat{\sigma}_{n-1}^2 = \frac{1}{n-1} \left( \sum_{i=1}^n (X_i - \bar{X})^2 \right)$$

es un estimador insesgado de  $\sigma^2$

Se denota

$$\hat{\sigma}_n^2 = \frac{1}{n} \left( \sum_{i=1}^n (X_i - \bar{X})^2 \right)$$

## Problema

P1

Sea  $X_1, X_2, \dots, X_n$  una muestra de  $X$  tal que  $E(X) = \mu$  y  $Var(X) = \sigma^2$

Mostrar que  $E\left(\sum_{i=1}^n (X_i - \bar{X})^2\right) = (n-1) \cdot \sigma^2$

Esto genera que

$$\hat{\sigma}_{n-1}^2 = \frac{1}{n-1} \left( \sum_{i=1}^n (X_i - \bar{X})^2 \right)$$

es un estimador insesgado de  $\sigma^2$

Se denota

$$\hat{\sigma}_n^2 = \frac{1}{n} \left( \sum_{i=1}^n (X_i - \bar{X})^2 \right)$$

## Problema

P2

Si  $X \sim N(\mu, \sigma^2)$ , mostrar que

$$\frac{(n-1) \cdot \hat{\sigma}_{n-1}^2}{\sigma^2} = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\sigma^2} \sim \chi_{n-1}^2$$

HINT:

$$\sum \left( \frac{X_i - \mu}{\sigma} \right)^2 = \frac{nS_n^2}{\sigma^2} + \left( \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \right)^2$$

Se puede probar que si  $X \sim N(\mu, \sigma^2)$ , entonces  $\bar{X}$  y  $\hat{\sigma}_{n-1}^2$  son independientes.

## Problema

P2

Si  $X \sim N(\mu, \sigma^2)$ , mostrar que

$$\frac{(n-1) \cdot \hat{\sigma}_{n-1}^2}{\sigma^2} = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\sigma^2} \sim \chi_{n-1}^2$$

HINT:

$$\sum \left( \frac{X_i - \mu}{\sigma} \right)^2 = \frac{nS_n^2}{\sigma^2} + \left( \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \right)^2$$

Se puede probar que si  $X \sim N(\mu, \sigma^2)$ , entonces  $\bar{X}$  y  $\hat{\sigma}_{n-1}^2$  son independientes.

## Problema

P2

Si  $X \sim N(\mu, \sigma^2)$ , mostrar que

$$\frac{(n-1) \cdot \hat{\sigma}_{n-1}^2}{\sigma^2} = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\sigma^2} \sim \chi_{n-1}^2$$

HINT:

$$\sum \left( \frac{X_i - \mu}{\sigma} \right)^2 = \frac{nS_n^2}{\sigma^2} + \left( \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \right)^2$$

Se puede probar que si  $X \sim N(\mu, \sigma^2)$ , entonces  $\bar{X}$  y  $\hat{\sigma}_{n-1}^2$  son independientes.

## Problema

P3

Si  $X \sim N(\mu, \sigma^2)$ , mostrar que

$$ECM(\hat{\sigma}^2_{n+1}) < ECM(\hat{\sigma}^2_n) < ECM(\hat{\sigma}^2_{n-1})$$

# Métodos para encontrar Estimadores

Hasta ahora, tenemos algunas herramientas para determinar si un estimador dado cumple o no algunas “buenas” propiedades.

Necesitamos tener algunos métodos que nos permitan llegar a buenos estimadores.



# Estimador de Máxima Verosimilitud

## Definición ESTIMADOR DE MÁXIMA VEROSIMILITUD

El estimador de máxima verosimilitud de  $\theta$ , llamado  $\hat{\theta}$ , basado en una muestra  $X_1, X_2, \dots, X_n$  es el valor de  $\theta$  que maximiza a  $L(X_1, X_2, \dots, X_n; \theta)$  considerado como una función de  $\theta$  para la muestra dada.  $L$  está definida como

$$L(X_1, X_2, \dots, X_n; \theta) = f(X_1; \theta) \cdot f(X_2; \theta) \cdot \dots \cdot f(X_n; \theta)$$

# Cómo llegar al EMV

Dedemos maximizar. Para ello, lo más intuitivo es

$$\frac{\partial}{\partial \theta} = 0$$

Sin embargo, notemos que deberíamos derivar muchos productos!!!  
¿Qué hacemos?

USAMOS  $\ln$

es decir

$$\frac{\partial}{\partial \theta} \ln L(X_1, X_2, \dots, X_n; \theta) = 0$$

# Cómo llegar al EMV

Dedemos maximizar. Para ello, lo más intuitivo es

$$\frac{\partial}{\partial \theta} = 0$$

Sin embargo, notemos que deberíamos derivar muchos productos!!!  
¿Qué hacemos?

USAMOS  $\ln$

es decir

$$\frac{\partial}{\partial \theta} \ln L(X_1, X_2, \dots, X_n; \theta) = 0$$

# Cómo llegar al EMV

Dedemos maximizar. Para ello, lo más intuitivo es

$$\frac{\partial}{\partial \theta} = 0$$

Sin embargo, notemos que deberíamos derivar muchos productos!!!  
¿Qué hacemos?

**USAMOS ln**

es decir

$$\frac{\partial}{\partial \theta} \ln L(X_1, X_2, \dots, X_n; \theta) = 0$$

# Cómo llegar al EMV

Dedemos maximizar. Para ello, lo más intuitivo es

$$\frac{\partial}{\partial \theta} = 0$$

Sin embargo, notemos que deberíamos derivar muchos productos!!!  
¿Qué hacemos?

**USAMOS ln**

es decir

$$\frac{\partial}{\partial \theta} \ln L(X_1, X_2, \dots, X_n; \theta) = 0$$

# Propiedades del EMV

- El EMV puede ser sesgado.
- Propiedad de Invarianza  
Es decir si  $\hat{\theta}$  es el EMV de  $\theta$ , entonces  $g(\hat{\theta})$  es el EMV de  $g(\theta)$

¿Qué pasa si  $L$  (función de verosimilitud) depende de más de un parámetro?

$$L(X_1, X_2, \dots, X_n; \alpha, \beta)$$

Simplemente tomamos ambas derivadas parciales y resolvemos un sistema.

# Propiedades del EMV

- El EMV puede ser sesgado.
- Propiedad de Invarianza  
Es decir si  $\hat{\theta}$  es el EMV de  $\theta$ , entonces  $g(\hat{\theta})$  es el EMV de  $g(\theta)$

¿Qué pasa si  $L$  (función de verosimilitud) depende de más de un parámetro?

$$L(X_1, X_2, \dots, X_n; \alpha, \beta)$$

Simplemente tomamos ambas derivadas parciales y resolvemos un sistema.

# Propiedades del EMV

- El EMV puede ser sesgado.
- Propiedad de Invarianza  
Es decir si  $\hat{\theta}$  es el EMV de  $\theta$ , entonces  $g(\hat{\theta})$  es el EMV de  $g(\theta)$

¿Qué pasa si  $L$  (función de verosimilitud) depende de más de un parámetro?

$$L(X_1, X_2, \dots, X_n; \alpha, \beta)$$

Simplemente tomamos ambas derivadas parciales y resolvemos un sistema.



## Problema

## P4

Sea  $X \sim \text{Gamma}(r, \alpha)$ , y  $X_1, X_2, \dots, X_n$  una muestra aleatoria.

a) Encontrar el EMV de  $r$  y  $\alpha$ .

b) Asumiendo  $r$  conocido, encontrar el EMV de  $\lambda = \frac{1}{\alpha}$ . Estudiar insesgamiento y consistencia.

c) ¿Cuál es la distribución muestral de  $\hat{\lambda}$ ?

## Distribución Gamma

- Gamma  $G(r, \alpha)$

Sean  $r, \alpha > 0$ . Si  $X \sim G(r, \alpha)$ , se tiene

$$f_X(x) = \begin{cases} \frac{\alpha^r x^{r-1} \cdot e^{-\alpha x}}{\Gamma(r)} & x > 0 \\ 0 & x \leq 0 \end{cases}$$

## Problema

## P4

Sea  $X \sim \text{Gamma}(r, \alpha)$ , y  $X_1, X_2, \dots, X_n$  una muestra aleatoria.

a) Encontrar el EMV de  $r$  y  $\alpha$ .

b) Asumiendo  $r$  conocido, encontrar el EMV de  $\lambda = \frac{1}{\alpha}$ . Estudiar insesgamiento y consistencia.

c) ¿Cuál es la distribución muestral de  $\hat{\lambda}$ ?

## Distribución Gamma

- Gamma  $G(r, \alpha)$

Sean  $r, \alpha > 0$ . Si  $X \sim G(r, \alpha)$ , se tiene

$$f_X(x) = \begin{cases} \frac{\alpha^r x^{r-1} \cdot e^{-\alpha x}}{\Gamma(r)} & x > 0 \\ 0 & x \leq 0 \end{cases}$$



## Problema

P5

- Determinar el EMV de  $p$  de una Distribución Binomial.
- Mostrar que no existe estimador insesgado de

$$\theta = \frac{p}{1-p}$$

# Bibliografía

-  Paul L. Meyer.  
*Probabilidad y Aplicaciones Estadísticas.*
-  W. Mendenhall.  
*Mathematical statistics with applications*