

Introducción a la Econometría

Tema 4 — Estimación y muestreo

Marcos Bujosa y
Gustavo A. Marrero

Material de apoyo para el curso *Introducción a la Econometría* de la licenciatura en Economía de la Universidad Complutense de Madrid.

Copyright © 2003–2007 Marcos Bujosa y Gustavo A. Marrero



Algunos derechos reservados. Esta obra está bajo una licencia Reconocimiento-Compartirlgua de Creative Commons. Para ver una copia de esta licencia, visite <http://creativecommons.org/licenses/by-sa/2.5/es/deed.es> o envíe una carta a Creative Commons, 559 Nathan Abbott Way, Stanford, California 94305, USA.

Puede encontrar la última versión de este material en:

<http://www.ucm.es/info/ecocuan/mbb/index.html#ietria>

Índice

Índice	3
1. Introducción	6
2. Inferencia paramétrica	11
3. Estimación puntual y por intervalos (repass)	17
4. Distribuciones asociadas al muestreo (repass)	24
4.1. Distribución de la media muestral	24
4.2. Distribución de la varianza y la cuasi-varianza muestral . .	29
4.3. Distribución de la media muestral cuando la varianza NO es conocida	32
4.4. Otras distribuciones	35
5. Transparencias	40

Este es un material de apoyo a las clases. En ningún caso sustituye a los libros de texto que figuran en el programa de la asignatura; textos que el alumno debe estudiar para afrontar el examen final con ciertas garantías de éxito.

El programa se cubre con los siguientes capítulos de libro de texto [Novales \(1997\)](#)¹:

Capítulos 1 a 3: Estos temas han sido cubiertos en asignaturas anteriores, y debido a su bajo nivel de complejidad no se verán en clase (aunque forman parte del programa).

Capítulos 4 a 6: Estos temas han sido cubiertos en las asignaturas [Estadística I](#) y [II](#). Se realizará un breve repaso en clase (una semana o semana y media como máximo), asumiendo que el alumno es capaz de preparar por su cuenta esta parte.

Capítulos 7 y 8: completos

Capítulo 9: secciones 9.4 a 9.6

Capítulos 10 y 12: completos

¹Otros excelentes manuales en castellano son [Peña \(2001\)](#), [Peña \(2002\)](#) y [Peña y Romo \(1997\)](#).

1. Introducción



$$\begin{aligned} S &\rightarrow \mathbb{R}_X \\ (\mathfrak{B}, P(\cdot)) &\rightarrow \{f_x(x; \theta), \theta \in \Theta\} \end{aligned}$$

Llamamos **Soporte** al conjunto \mathbb{R}_X de posibles valores de la v.a.

Llamamos **Modelo de Probabilidad** a la familia o colección de funciones de densidad

$$\Phi = \{f_x(x; \theta), \theta \in \Theta, x \in \mathbb{R}_X\}$$

Llamamos **Espacio Paramétrico** al conjunto $\theta \in \Theta$ de posibles valores de los parámetros de las funciones de densidad.



1. Postulamos a priori una familia de densidades como mecanismo estocástico subyacente.



1. Postulamos a priori una familia de densidades como mecanismo estocástico subyacente.

a) debemos elegir aquel **Modelo de Probabilidad** más adecuado a los datos

- histograma $\rightarrow f_x(x; \theta)$
- datos pueden restringir \mathbb{R}_x y espacio paramétrico, Θ

1. Postulamos a priori una familia de densidades como mecanismo estocástico subyacente.

a) debemos elegir aquel **Modelo de Probabilidad** más adecuado a los datos

- histograma $\rightarrow f_{\mathbf{x}}(x; \boldsymbol{\theta})$
- datos pueden restringir $\mathbb{R}_{\mathbf{x}}$ y espacio paramétrico, Θ

b) Elegimos una familia (no una función en particular)

$$\Phi = \{f_{\mathbf{x}}(x; \boldsymbol{\theta}), \boldsymbol{\theta} \in \Theta, x \in \mathbb{R}_{\mathbf{x}}\}$$

donde los parámetros son desconocidos.



1. Postulamos a priori una familia de densidades como mecanismo estocástico subyacente.

a) debemos elegir aquel **Modelo de Probabilidad** más adecuado a los datos

- histograma $\rightarrow f_{\mathbf{x}}(x; \theta)$
- datos pueden restringir $\mathbb{R}_{\mathbf{x}}$ y espacio paramétrico, Θ

b) Elegimos una familia (no una función en particular)

$$\Phi = \{f_{\mathbf{x}}(x; \theta), \theta \in \Theta, x \in \mathbb{R}_{\mathbf{x}}\}$$

donde los parámetros son desconocidos.

2. Inferencia estadística \Rightarrow modelo de probabilidad

(Tema 4 y siguientes)



Estudiar propiedades y/o relaciones estocásticas de poblaciones

X : Renta familia Madrileña

Y : Renta familia Barcelonesa



Estudiar propiedades y/o relaciones estocásticas de poblaciones

X : Renta familia Madrileña

Y : Renta familia Barcelonesa

Podemos preguntarnos por

$$E(Y) = 10000?; \quad E(Y) \in (8000, 15000)?;$$

$$E_{y|x}(Y | 5000) > E(Y)?;$$

$$\text{Var}(Y) > \text{Var}(X); \quad P(Y > X); \quad f_Y(y) \sim N(\mu_Y, \sigma_Y^2)$$



Estudiar propiedades y/o relaciones estocásticas de poblaciones

X : Renta familia Madrileña

Y : Renta familia Barcelonesa

Podemos preguntarnos por

$$E(Y) = 10000?; \quad E(Y) \in (8000, 15000)?;$$

$$E_{Y|X}(Y | 5000) > E(Y)?;$$

$$\text{Var}(Y) > \text{Var}(X); \quad P(Y > X); \quad f_Y(y) \sim N(\mu_Y, \sigma_Y^2)$$

Conociendo $f_{XY}(x, y; \theta)$ respuesta inmediata.



Estudiar propiedades y/o relaciones estocásticas de poblaciones

X : Renta familia Madrileña

Y : Renta familia Barcelonesa

Podemos preguntarnos por

$$E(Y) = 10000?; \quad E(Y) \in (8000, 15000)?;$$

$$E_{Y|X}(Y | 5000) > E(Y)?;$$

$$\text{Var}(Y) > \text{Var}(X); \quad P(Y > X); \quad f_Y(y) \sim N(\mu_Y, \sigma_Y^2)$$

Conociendo $f_{XY}(x, y; \theta)$ respuesta inmediata.

Pero...

A veces sólo conocemos $f_{XY}(x, y)$ pero no θ (Inferenc. paramétrica)



Estudiar propiedades y/o relaciones estocásticas de poblaciones

X : Renta familia Madrileña

Y : Renta familia Barcelonesa

Podemos preguntarnos por

$$E(Y) = 10000?; \quad E(Y) \in (8000, 15000)?;$$

$$E_{Y|X}(Y | 5000) > E(Y)?;$$

$$\text{Var}(Y) > \text{Var}(X); \quad P(Y > X); \quad f_Y(y) \sim N(\mu_Y, \sigma_Y^2)$$

Conociendo $f_{XY}(x, y; \theta)$ respuesta inmediata.

Pero...

A veces sólo conocemos $f_{XY}(x, y)$ pero no θ (Inferenc. paramétrica)

A veces ni siquiera conocemos $f_{XY}(x, y)$ (Inferenc. no paramétrica)

2. Inferencia paramétrica



Momentos Teóricos (o *momentos de una distribución*): valor esperado de funciones $g(X)$

$$E(g(X)) = \int_{\mathbb{R}_X} g(x) \cdot f_X(x; \theta) dx$$



Momentos Teóricos (o *momentos de una distribución*): valor esperado de funciones $g(X)$

$$E(g(X)) = \int_{\mathbb{R}_X} g(x) \cdot f_X(x; \theta) dx$$

por tanto son funciones $h(\theta; x)$ de los parámetros

$$E(g(X)) = h(\theta; x)$$



Momentos Teóricos (o *momentos de una distribución*): valor esperado de funciones $g(X)$

$$E(g(X)) = \int_{\mathbb{R}_X} g(x) \cdot f_X(x; \theta) dx$$

por tanto son funciones $h(\theta; x)$ de los parámetros

$$E(g(X)) = h(\theta; x)$$

Inferencia: sobre valor de θ mediante *momentos muestrales* (dada x).



Llamamos **modelo muestral** de tamaño n , \mathbf{X} , a

$$\mathbf{X} \equiv (X_1, X_2, \dots, X_n)$$

y llamamos **muestra** a una realización de \mathbf{X}

$$\mathbf{x} \equiv (x_1, x_2, \dots, x_n) \in \mathbb{R}_{\mathbf{x}}^n.$$

Supondremos los datos observados como realizaciones del **modelo muestral** (i.e., una muestra).



Modelo estadístico

1. Modelo probabilístico

$$f_{x_i}(x_i; \theta)$$

2. Modelo muestral

$$\mathbf{X} = (X_1, X_2, \dots, X_n)$$



Modelo estadístico

1. Modelo probabilístico

$$f_{x_i}(x_i; \theta)$$

2. Modelo muestral

$$\mathbf{X} = (X_1, X_2, \dots, X_n)$$



Distribución conjunta
de \mathbf{X}

$$f_{\mathbf{X}}(\mathbf{x}, \theta)$$

**Modelo estadístico**

1. Modelo probabilístico

$$f_{\mathbf{x}_i}(x_i; \theta)$$

2. Modelo muestral

$$\mathbf{X} = (X_1, X_2, \dots, X_n)$$

**Distribución conjunta
de \mathbf{X}**

$$f_{\mathbf{X}}(\mathbf{x}, \theta)$$

Datos observados (muestra)

$$\mathbf{x} = (x_1, x_2, \dots, x_n)$$

Realización de \mathbf{X} (un punto del soporte $\mathbb{R}_{\mathbf{x}}^n$)



Modelo estadístico

1. Modelo probabilístico

$$f_{\mathbf{x}_i}(x_i; \theta)$$

2. Modelo muestral

$$\mathbf{X} = (X_1, X_2, \dots, X_n)$$



Distribución conjunta
de \mathbf{X}

$$f_{\mathbf{X}}(\mathbf{x}, \theta)$$



Datos observados (muestra)

$$\mathbf{x} = (x_1, x_2, \dots, x_n)$$

Realización de \mathbf{X}

(un punto del soporte $\mathbb{R}_{\mathbf{x}}^n$)



Inferencia estadística

- Estimación
- Contrastación
- Predicción



Llamamos *estadístico* a una función del modelo muestral

$$g(X_1, X_2, \dots, X_n) \equiv g(\mathbf{X});$$

es por tanto v.a.

Llamamos *estadístico* a una función del modelo muestral

$$g(X_1, X_2, \dots, X_n) \equiv g(\mathbf{X});$$

es por tanto v.a.

Sus momentos respecto al origen son

$$E([g(\mathbf{X})]^r) = \int \cdots \int_{\mathbb{R}_{\mathbf{X}}^n} [g(\mathbf{x})]^r f_{\mathbf{X}}(\mathbf{x}, \boldsymbol{\theta}) dx_1 \cdots dx_n$$

donde $\mathbf{x} \equiv (x_1, x_2, \dots, x_n) \in \mathbb{R}_{\mathbf{X}}^n$.



El *muestreo aleatorio simple* (m.a.s.) supone que X_i son idéntica e independientemente distribuidas

$$X_i \sim \text{iid}; \quad i = 1, \dots, n.$$



El *muestreo aleatorio simple* (m.a.s.) supone que X_i son idéntica e independientemente distribuidas

$$X_i \sim \text{iid}; \quad i = 1, \dots, n.$$

Por tanto, $f_{x_1}(x) = f_{x_2}(x) \cdots = f_{x_n}(x) = f_x(x)$;
es decir, cada x_i proviene de una misma población.



El *muestreo aleatorio simple* (m.a.s.) supone que X_i son idéntica e independientemente distribuidas

$$X_i \sim \text{iid}; \quad i = 1, \dots, n.$$

Por tanto, $f_{X_1}(x) = f_{X_2}(x) \cdots = f_{X_n}(x) = f_X(x)$;
es decir, cada x_i proviene de una misma población.

Además (por la independenciam)

$$f_{X_1, \dots, X_n}(x_1, \dots, x_n) = \prod_{i=1}^n f_{X_i}(x) = (f_X(x))^n$$

y

$$M_{X_1, \dots, X_n} = \prod_{i=1}^n M_{X_i} = (M_X)^n$$

3. Estimación puntual y por intervalos (repaso)



Supongamos una muestra aleatoria simple (*m.a.s.*)

$$\mathbf{x} \equiv (x_1, x_2, \dots, x_n);$$

realización del muestreo aleatorio simple (modelo muestral)

$$\mathbf{X} \equiv (X_1, X_2, \dots, X_n) \text{ con } f_{\mathbf{x}}(\mathbf{x}; \boldsymbol{\theta}).$$


Buscamos un valor para el vector $\boldsymbol{\theta}$ que “*de algún modo*” es más acorde con la muestra \mathbf{x} .



x es *una* de las posibles realizaciones de X .

x es una de las posibles realizaciones de \mathbf{X} .


Buscamos una regla que elija un valor de θ para cada x .



estimación: $\hat{\theta} = g(x_1, x_2, \dots, x_n) = g(\mathbf{x})$

- (Resumen de algún aspecto de la información muestral)

estimador: $\hat{\theta} = g(X_1, X_2, \dots, X_n) = g(\mathbf{X})$



- Modelo muestral: (X_1, X_2, X_3)
- Estimador: $\hat{\theta} = (X_1 + X_2 + X_3)/3$
- Primera muestra: $x = (10, 12, 11)$
- Estimación con primera muestra: $\hat{\theta} = 11$
(es un valor puntual, una realización de $\hat{\theta}$)

Boxmodels (Sumas y medias)



Existen infinidad de posibles estimadores.

- problema de la elección (*Inssegadez, eficiencia*).
 - Máxima verosimilitud
 - Mínimos cuadrados
 - Método de los momentos
 - Otros.



Existen infinidad de posibles estimadores.

- problema de la elección (*Insegadez, eficiencia*).
 - Máxima verosimilitud
 - Mínimos cuadrados
 - Método de los momentos
 - Otros.

Estimación puntual es *tan sólo* una realización de $\hat{\theta}$.

Estimación puntual es *poco* informativa.



Existen infinidad de posibles estimadores.


- problema de la elección (*Insegadez, eficiencia*).
 - Máxima verosimilitud
 - Mínimos cuadrados
 - Método de los momentos
 - Otros.

Estimación puntual es *tan sólo* una realización de $\hat{\theta}$.

Estimación puntual es *poco* informativa.

Podemos decir más si conocemos la distribución de $\hat{\theta}$.

Buscamos una regla que elija, para cada x , un conjunto de valores que pueda contener el verdadero valor de θ con cierta probabilidad.



Deseamos que:

- el conjunto sea pequeño (precisión)
- la probabilidad de que *el verdadero* θ pertenezca al conjunto sea grande (confianza)

$$\left[h(\hat{\theta}_1), h(\hat{\theta}_2) \right] = g(\mathbf{X}_{(n)})$$

de tal manera que

$$P\left(h(\hat{\theta}_1) \leq \theta \leq h(\hat{\theta}_2) \right) = (1 - \alpha)$$

donde

- $(1 - \alpha)$ es el nivel de confianza.

Buscamos que $(1 - \alpha)$ sea grande; y $(\hat{\theta}_2 - \hat{\theta}_1)$ sea mínimo.

(Generalmente se fija $(1 - \alpha)$ y se busca que $(\hat{\theta}_2 - \hat{\theta}_1)$ sea mínimo.)

Necesitamos la distribución de $g(\mathbf{X}_{(n)})$

4. Distribuciones asociadas al muestreo (repass)

4.1. Distribución de la media muestral

ESTIMADOR DE LA ESPERANZA CUANDO LA VARIANZA ES CONOCIDA

Sea $X \sim N(\mu, \sigma^2)$ con σ^2 conocida.

Emplearemos como estimador de $E(X)$ la media aritmética

$$g(X_1, \dots, X_n) = \hat{x} = \frac{1}{n} \sum_{i=1}^n X_i$$

donde

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


o tipificando

$$\frac{\hat{x} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1).$$

DADO UN NIVEL DE CONFIANZA CALCULAMOS EL INTERVALO

Puesto que $\frac{\hat{x} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$.

$$P\left(a \leq \frac{\hat{x} - \mu}{\sigma/\sqrt{n}} \leq b\right) = 1 - \alpha$$



$$\mu \in \left[\hat{x} \pm \frac{\sigma}{\sqrt{n}} z_{\alpha/2} \right]; \quad \text{con probabilidad } 1 - \alpha.$$



X_i : Renta familia Madrileña i

$$n = 16; \quad \sum x_i = 2536; \quad X_i \sim N(\mu, 250);$$

$$(1 - \alpha) = 0.95 \implies z_{0.975} = 1.96$$

Entonces

$$\left[\frac{2536}{16} \pm \frac{\sqrt{250}}{\sqrt{16}} 1.96 \right] = [151, 025; 165, 975]$$

X_i : Renta familia Madrileña i

$$n = 16; \quad \sum x_i = 2536; \quad X_i \sim N(\mu, 250);$$

$$(1 - \alpha) = 0.95 \implies z_{0.975} = 1.96$$

Entonces

$$\left[\frac{2536}{16} \pm \frac{\sqrt{250}}{\sqrt{16}} 1.96 \right] = [151,025; 165,975]$$

Cálculo con muestras A, B, C, ...

$$\hat{\bar{x}}^A = 150,5 \rightarrow [143.025; 157.975]$$

X_i : Renta familia Madrileña i

$$n = 16; \quad \sum x_i = 2536; \quad X_i \sim N(\mu, 250);$$

$$(1 - \alpha) = 0.95 \implies z_{0.975} = 1.96$$

Entonces

$$\left[\frac{2536}{16} \pm \frac{\sqrt{250}}{\sqrt{16}} 1.96 \right] = [151,025; 165,975]$$

Cálculo con muestras A, B, C, ...

$$\hat{\bar{x}}^A = 150,5 \quad \rightarrow \quad [143.025; 157.975]$$

$$\hat{\bar{x}}^B = 164 \quad \rightarrow \quad [156.525; 171.475]$$

X_i : Renta familia Madrileña i

$$n = 16; \quad \sum x_i = 2536; \quad X_i \sim N(\mu, 250);$$

$$(1 - \alpha) = 0.95 \implies z_{0.975} = 1.96$$

Entonces

$$\left[\frac{2536}{16} \pm \frac{\sqrt{250}}{\sqrt{16}} 1.96 \right] = [151,025; 165,975]$$

Cálculo con muestras A, B, C, ...

$$\hat{\bar{x}}^A = 150,5 \quad \rightarrow \quad [143.025; 157.975]$$

$$\hat{\bar{x}}^B = 164 \quad \rightarrow \quad [156.525; 171.475]$$

$$\hat{\bar{x}}^C = 155 \quad \rightarrow \quad [147.525; 162.475]$$

...

...

...

X_i : Renta familia Madrileña i

$$n = 16; \quad \sum x_i = 2536; \quad X_i \sim N(\mu, 250);$$

$$(1 - \alpha) = 0.95 \implies z_{0.975} = 1.96$$

Entonces

$$\left[\frac{2536}{16} \pm \frac{\sqrt{250}}{\sqrt{16}} 1.96 \right] = [151,025; 165,975]$$

Cálculo con muestras A, B, C, ...

$$\hat{\bar{x}}^A = 150,5 \quad \rightarrow \quad [143.025; 157.975]$$

$$\hat{\bar{x}}^B = 164 \quad \rightarrow \quad [156.525; 171.475]$$

$$\hat{\bar{x}}^C = 155 \quad \rightarrow \quad [147.525; 162.475]$$

$$\dots \quad \dots \quad \dots$$

“verdadero valor” es $\mu = 155,2$ (pero es DESCONOCIDO!!!)

Boxmodels (Intervalos de confianza)



En economía generalmente se dispone de una única muestra (no hay laboratorio)



En economía generalmente se dispone de una única muestra (no hay laboratorio)

Si queremos aumentar el nivel de confianza...

$$(1 - \alpha) = 0.99 \implies z_{0.995} = 2.57$$

entonces

$$\left[\hat{x} \pm \frac{\sqrt{\sigma^2}}{\sqrt{n}} 2.57 \right] = [153, 81; 174, 158]$$

menor precisión!!



En economía generalmente se dispone de una única muestra (no hay laboratorio)

Si queremos aumentar el nivel de confianza...

$$(1 - \alpha) = 0.99 \implies z_{0.995} = 2.57$$

entonces

$$\left[\hat{x} \pm \frac{\sqrt{\sigma^2}}{\sqrt{n}} 2.57 \right] = [153, 81; 174, 158]$$

menor precisión!!

Dado $1 - \alpha$ podemos aumentar la precisión de dos formas

1. disminuir σ^2 (política de distribución de rentas)
2. aumentar n (tamaño de muestra)

4.2. Distribución de la varianza y la cuasi-varianza muestral

ESTIMADOR DE LA VARIANZA

Sean $X_i \sim \text{iid. } N(\mu, \sigma^2)$, con μ y σ^2 desconocidos.

Emplearemos como estimador de $\text{Var}(X_i)$ el estadístico:

$$g(X_1, \dots, X_n) = \sum_{i=1}^n \frac{(X_i - \hat{x})^2}{\sigma^2} = \frac{n\hat{s}^2}{\sigma^2} = \frac{(n-1)\hat{\mathfrak{s}}^2}{\sigma^2} \sim \chi_{(n-1)}^2$$

donde

$$\hat{s}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \hat{x})^2,$$

y


$$\hat{\mathfrak{s}}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \hat{x})^2 \quad (\text{insesgado}).$$

CÁLCULO DEL INTERVALO Puesto que

$$\frac{(n-1)\widehat{s}^2}{\sigma^2} \sim \chi_{(n-1)}^2$$

Fijado $(1 - \alpha)$ buscamos a y b tales que

$$P\left(a \leq \frac{(n-1)\widehat{s}^2}{\sigma^2} \leq b\right) = (1 - \alpha)$$



entonces $\sigma^2 \in \left[\frac{\widehat{s}^2(n-1)}{\chi_{(n-1,1-\alpha/2)}^2}, \frac{\widehat{s}^2(n-1)}{\chi_{(n-1,\alpha/2)}^2} \right]$ con prob. = $(1 - \alpha)$

4.3. Distribución de la media muestral cuando la varianza NO es conocida



ESTIMADOR DE LA ESPERANZA CUANDO LA VARIANZA NO ES CONOCIDA

Sea X , y sean $\text{Var}(X)$ y $E(X)$ desconocidas.

Emplearemos como estimador de $E(X)$ el estadístico:

$$g(X_1, \dots, X_n) = \frac{\hat{\bar{x}} - \mu}{\sqrt{\hat{s}^2/n}} \sim t_{n-1}.$$




CÁLCULO DEL INTERVALO Puesto que

$$\frac{\hat{x} - \mu}{\sqrt{\hat{s}^2/n}} \sim t_{n-1}$$

Fijado $(1 - \alpha)$ buscamos a y b tales que

$$P\left(a \leq \frac{\hat{x} - \mu}{\sqrt{\hat{s}^2/n}} \leq b\right) = (1 - \alpha)$$



entonces

$$\mu \in \left[\hat{x} \pm t_{n-1, \alpha/2} \cdot \sqrt{\hat{s}^2/n} \right] \text{ con Prob. } = (1 - \alpha).$$

4.4. Otras distribuciones



Sean X_1, X_2, \dots, X_n con $E(X_i) = \mu_i$, con $\text{Var}(X_i) = \sigma_i^2$ con $f_{X_i}(x_i)$ cualquiera; entonces si $Y = X_1 + X_2 + \dots + X_n$

$$\frac{Y - \sum \mu_i}{\sqrt{\sum \sigma_i^2}} \xrightarrow{d} N(0, 1);$$

por lo tanto

$$Y \xrightarrow{d} N\left(\sum \mu_i, \sum \sigma_i^2\right).$$

Tablas resumen de varios estadísticos

Parámetro	Estadístico pivote	Distribución	Intervalo de confianza
p	$\frac{\widehat{p} - p}{\sqrt{\frac{\widehat{p}\widehat{q}}{n}}}$	$N(0, 1)$	$\widehat{p} \pm z_{\alpha/2} \sqrt{\frac{\widehat{p}\widehat{q}}{n}}$
$p_1 - p_2$	$\frac{(\widehat{p}_1 - \widehat{p}_2) - (p_1 - p_2)}{\sqrt{\frac{\widehat{p}_1 \widehat{q}_1}{n_1} + \frac{\widehat{p}_2 \widehat{q}_2}{n_2}}}$	$N(0, 1)$	$\widehat{p}_1 - \widehat{p}_2 \pm z_{\alpha/2} \sqrt{\frac{\widehat{p}_1 \widehat{q}_1}{n_1} + \frac{\widehat{p}_2 \widehat{q}_2}{n_2}}$

Cuadro 1: Intervalos de confianza para proporciones; ($q = 1 - p$)

Parámetro	Estadístico pivote	Distribución	Intervalo de confi
$\mu;$ σ conocido	$\frac{(\bar{x} - \mu)}{\sqrt{\sigma^2/n}}$	$N(0, 1)$	$\bar{x} \pm z_{\frac{\alpha}{2}} \sqrt{\sigma^2/n}$
$\mu;$ σ desconocido	$\frac{(\bar{x} - \mu)}{\sqrt{\hat{s}^2/n}}$	t_{n-1}	$\bar{x} \pm t_{\frac{\alpha}{2}} \sqrt{\hat{s}^2/n}$
σ^2	$(n-1)\hat{s}^2/\sigma^2$	χ_{n-1}^2	$\frac{\hat{s}^2(n-1)}{\chi_{1-\frac{\alpha}{2}}^2}, \frac{\hat{s}^2(n-1)}{\chi_{\frac{\alpha}{2}}^2}$
$\mu_1 - \mu_2$ σ_1, σ_2 conocidas	$\frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}}}$	$N(0, 1)$	$\bar{x}_1 - \bar{x}_2 \pm z_{\frac{\alpha}{2}} \sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}}$
$\mu_1 - \mu_2;$ $\sigma_1 \neq \sigma_2$	$\frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{\hat{s}_1^2}{n} + \frac{\hat{s}_2^2}{m}}}$	t_{n+m-2}	$\bar{x}_1 - \bar{x}_2 \pm t_{\frac{\alpha}{2}} \sqrt{\frac{\hat{s}_1^2}{n} + \frac{\hat{s}_2^2}{m}}$
$\mu_1 - \mu_2;$ $\sigma_1 = \sigma_2$	$\frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{(n-1)\hat{s}_1^2 + (m-1)\hat{s}_2^2}{n+m-2} \left(\frac{1}{n} + \frac{1}{m}\right)}}$	t_{n+m-2}	$\bar{x}_1 - \bar{x}_2 \pm t_{\frac{\alpha}{2}} \sqrt{\frac{\hat{s}_1^2 + \hat{s}_2^2}{n+m-2} \left(\frac{1}{n} + \frac{1}{m}\right)}$
$\frac{\sigma_2^2}{\sigma_1^2}$	$\frac{\hat{s}_1^2/\sigma_1^2}{\hat{s}_2^2/\sigma_2^2} = \frac{\hat{s}_1^2}{\hat{s}_2^2} \frac{\sigma_2^2}{\sigma_1^2}$	$F_{n-1, m-1}$	$F_a \frac{\hat{s}_2^2}{\hat{s}_1^2} \leq \frac{\sigma_2^2}{\sigma_1^2} \leq F_b \frac{\hat{s}_2^2}{\hat{s}_1^2}$

5. Trasparencias

Lista de Trasparencias

- 1 De $(S, \mathfrak{B}, P(\cdot))$ a un modelo de probabilidad: historia en símbolos
- 2 Modelado empírico
- 3 Inferencia estadística
- 4 Esquema Parte de Inferencia
- 5 Parámetros y momentos: ¿Qué relación hay?
- 6 Inferencia estadística
- 7 Inferencia estadística
- 8 Estadístico
- 9 Muestreo aleatorio simple
- 10 Estimación
- 11 Estimador puntual
- 12 Estimador puntual de la esperanza
- 13 Estimador puntual
- 14 Estimador por intervalos
- 15 Estimador por intervalos
- 16 Distribución de la media muestral: bajo normalidad
- 17 Distribución de la media muestral: bajo normalidad
- 18 Intervalo de confianza: ejemplo

- 19 Intervalo de confianza: ejemplo
- 20 Distribución de la varianza muestral: bajo normalidad
- 21 Distribución de la varianza muestral: bajo normalidad
- 22 Distribución de la media muestral: bajo normalidad (varianza desconocida)
- 23 Distribución de la media muestral: bajo normalidad (varianza desconocida)
- 24 teorema central del Límite
- 25 Partes del temario

6. Bibliografía

- Novales, A. (1997). *Estadística y Econometría*. McGraw-Hill, Madrid, primera ed. ISBN 84-481-0798-5. 5
- Peña, D. (2001). *Fundamentos de Estadística*. Alianza Editorial, Madrid. ISBN 84-206-8696-4. 5
- Peña, D. (2002). *Regresión y diseño de experimentos*. Alianza Editorial, Madrid. ISBN 84-206-8695-6. 5
- Peña, D. y Romo, J. (1997). *Introducción a la Estadística para la Ciencias Sociales*. McGraw-Hill, Madrid. ISBN 84-481-1617-8. 5

Partes del temario

- Tema 1 IntEctr-T01
- Tema 2 IntEctr-T02
- Tema 3 IntEctr-T03
- Tema 4 IntEctr-T04
- Tema 5 IntEctr-T05
- Tema 6 IntEctr-T06
- Tema 7 IntEctr-T07