

# Tema 8

psicologia.isipedia.com

## ESTIMACIÓN

### Conceptos previos

#### *Población y muestra:*

**Población** se refiere al conjunto total de elementos que se quieren estudiar una o más características. Debe estar bien definida. Llamaremos  $N$  al número total de elementos de una población. También se suelen utilizar los términos *individuos, sujetos y casos* para referirnos a los elementos de la población.

Cuando se dispone de un **censo** (listado) de la población, se puede estudiar a todos ellos.

No siempre es factible estudiar a la totalidad de una población, por lo que se estudia un subconjunto de los elementos totales; es decir, un **muestra**. Llamaremos  $n$  al número de los elementos de una muestra.

#### *Muestreo:*

El muestreo es un proceso de selección con el fin de obtener una muestra lo más semejante posible a la población y así obtener estimaciones precisas. El tamaño es una característica esencial; ya que debe ser lo suficientemente amplia para representar adecuadamente las propiedades de la población y reducida para que pueda ser examinada en la práctica.

El muestreo *probabilístico* se conoce la probabilidad asociada a una muestra y cada elemento de la población tiene una probabilidad conocida de pertenecer a la muestra. El *no-probabilístico* se desconoce, o no se tiene en cuenta, la probabilidad asociada a cada muestra y se selecciona la que más le parezca representativa al investigador.

Una forma de obtener una muestra de una población homogénea es utilizar:

- El *muestreo aleatorio simple*; por el cual se garantiza que cada elemento de la población tenga la misma probabilidad de formar parte de la muestra. Primero se asigna un número a cada elemento y

después mediante algún medio (sorteo, papeletas,...) se elijen tantos elementos como sea necesario para la muestra.

- Cuando los elementos están ordenados o pueden ordenarse se utiliza el **muestreo sistemático**. Se selecciona al azar entre los que ocupan los lugares  $\frac{N}{n}$ . Ejemplo:  $N = 100$ ;  $n = 5$ ;  $100/5 = 20$ ; escogeríamos los elementos situados en las posiciones 20. El riesgo de este muestreo es la falta de representación; que se pudiese dar, del total de los elementos.
- Cuando topamos con una población heterogénea, utilizamos el **muestreo estratificado**. Se emplea cuando disponemos de información suficiente sobre alguna característica y podemos elegir una muestra en función del número de elementos según estas características o estratos.
- Ante poblaciones desordenadas y conglomeradas en grupos, se emplea el **muestreo por conglomerados**; donde se van seleccionando de todos los grupos, subgrupos, clases, ... y finalmente de los elementos restantes la muestra.
- De la unión del estratificado y del conglomerado, surge otro **muestreo el polietápico**.

En ocasiones el muestreo es muy costoso y se recurre a métodos no probabilísticos:

- El **muestreo por cuotas** (accidental) se basa en un buen conocimiento de los estratos o individuos más representativos para la investigación. Similar al estratificado pero carente del carácter aleatorio.
- El **muestreo opinático** (intencional) muestra el interés por incluir en la muestra a grupos supuestamente típicos.
- El **causal** (incidental) selección de los individuos de fácil acceso.
- **Bola de nieve**; donde un elemento seleccionado lleva a otro y éste a otro y así sucesivamente hasta completar la muestra.

Una muestra es representativa si exhibe internamente el mismo grado de diversidad que la población y es aleatoria si los elementos han sido extraídos al azar de la población.

## Inferencia estadística

El valor estadístico obtenido de una muestra (como media) no será igual al

valor del parámetro de población. Para inferir un parámetro a partir de un estadístico hay que aplicar herramientas estadísticas de tipo inferencial como la **estimación por intervalo** (intervalos de confianza) o contraste de hipótesis.

## Estimación de la media

La media muestral es una variable aleatoria que toma un valor según la muestra concreta que se obtenga. Se denomina **distribución muestral de la media** a su función de probabilidad.

La **distribución muestral de un estadístico** es un concepto central, tanto de la estimación como del contraste de hipótesis.

### Distribución muestral de la media

Una función de probabilidad queda caracterizada por su forma, su media y su varianza. La media de la distribución muestral de la media ( $\mu_{\bar{x}}$ ) es igual a la media de la población ( $\mu$ ). La varianza de la distribución muestral de la media es  $\frac{\sigma^2}{n}$  y la desviación típica de la distribución muestral de la media, denominada error típico de la media, es  $\sigma_x = \sqrt{\frac{\sigma^2}{n}} = \frac{\sigma}{\sqrt{n}}$ .

La forma de la distribución original de la media se parece a una distribución normal aunque la distribución original de la variable en la población no es normal.

Dado el muestreo aleatorio simple:

- Si la distribución de  $X$  en la población es normal con media  $\mu$  y desviación típica  $\sigma$ , entonces la distribución muestral de la  $\bar{X}$  es normal

$$\left[ \mu, \frac{\sigma}{\sqrt{n}} \right]$$

- Si la distribución de  $X$  en la población no es normal con media  $\mu$  y desviación típica  $\sigma$ , entonces la distribución muestral de la  $\bar{X}$  tiende a la normal a medida que  $n$  crece (**Teorema Central del Límite**), siendo la aproximación buena para  $n \geq 30$ .

**Media, varianza y desviación típica de la variable cuantitativa  $X$  en la población y en la muestra, y de la distribución muestral de la media ( $\bar{X}$ ).**

	Población	Muestra	Distribución muestral
--	-----------	---------	-----------------------

			de la media
<b>Media</b>	$\mu = \frac{\sum X}{N}$	$\bar{X} = \frac{\sum X}{n}$	$\mu_{\bar{x}} = \mu$
<b>Varianza</b>	$\sigma^2 = \frac{\sum (X - \mu)^2}{N}$	$S^2_{n-1} = \frac{\sum (X - \bar{X})^2}{n - 1}$ Cuasivarianza	$\sigma^2_{\bar{x}} = \frac{\sigma^2}{n}$
<b>Desviación típica</b>	$\sigma = \sqrt{\frac{\sum (X - \mu)^2}{N}}$	$S^2_{n-1} = \sqrt{\frac{\sum (X - \bar{X})^2}{n - 1}}$ Cuasidesviación típica	$\Sigma_{\bar{x}} = \sqrt{\frac{\sigma^2}{n}} = \frac{\sigma}{\sqrt{n}}$ Error típico de la media

### *La media como estimador*

Un estimador es un estadístico que se utiliza para estimar un parámetro. Por lo que la media de la muestra es un estimador de la media poblacional; y el valor del estimador en una muestra se denomina **estimación** o **estimación puntual**.

La media muestral  $\bar{X}$  es un estimador **insesgado** de la media poblacional ( $\mu$ ). El error típico de la media es un indicador de la precisión de la estimación de la media; cuanto menor es el error típico, mayor es la precisión. Dependiendo de la desviación típica de la población y del tamaño de la muestra.

### **Estimación de la proporción**

Para la obtención de la distribución muestral de la proporción se puede hacer como la media.

### *Distribución muestral de la proporción*

Sea  $X$  una variable que sólo toma valores 0 y 1, la proporción de la muestra  $P$  se define como:

$$P = \frac{\sum X}{n}$$

Dado el muestreo aleatorio simple, el estadístico proporción ( $P$ ) se distribuye según una binomial:

$$\mu_p = \pi \text{ y } \sigma^2_p = \frac{\pi (1 - \pi)}{n}$$

Como  $P$  es la media de los valores de  $X$  en la muestra, según el Teorema Central del Límite, a medida que el tamaño crece, la distribución muestral de la proporción tiende a la normal con media  $\pi$  y varianza  $\frac{\pi (1 - \pi)}{n}$ .

Cuanto más alejado esté  $\pi$  de 0,5, más elementos debe tener la muestra para realizar la aproximación a la normal.

***Media, varianza y desviación típica de la variable dicotómica o dicotomizada (X) en la población y en la muestra, y de la distribución muestral de la proporción (P):***

	Población	Muestra	Distribución muestral de la proporción (P)
<b>Media</b>	$\pi = \frac{\sum X}{N}$ donde X: 0,1	$P = \frac{\sum X}{n}$ donde X: 0,1	$\mu_p = \mu$
<b>Varianza</b>	$\sigma^2 = \pi (1 - \pi)$	$S^2 = P (1 - P)$	$\sigma_p^2 = \frac{\pi (1 - \pi)}{n}$
<b>Desviación típica</b>	$\sigma = \sqrt{\pi (1 - \pi)}$	$S = \sqrt{P (1 - P)}$	$\sigma_p = \sqrt{\frac{\pi (1 - \pi)}{n}}$ Error típico de la proporción

### *La proporción como estimador*

La proporción muestral (p) es un estimador insesgado de la proporción poblacional ( $\pi$ ).

El error típico de la proporción, es un indicador de la precisión de la estimación de la proporción. Cuanto menor es el error típico, mayor es la precisión.

## **Intervalos de confianza**

### *Concepto*

La finalidad de un intervalo de confianza es estimar un parámetro desconocido de una población a partir de una muestra. Al estimar la media de la población a partir de una muestra, podemos cometer un error de estimación  $|\bar{X} - \mu|$ .

La estimación por intervalo consiste en acotar el error con una alta probabilidad  $1 - \alpha$  (**nivel de confianza**) de forma que  $|X - \mu|$  no sea superior a un estimado máximo ( $E_{\text{máx}}$ ).

El error de estimación máximo ( $E_{\text{máx}}$ ) es función de la variabilidad de la variable en la población, del nivel de confianza (n.c.) y del tamaño de la muestra:

$$E_{\text{máx}} = z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}$$

donde:

- $z_{1-\alpha/2}$  es función del n.c.  $= 1 - \alpha$  y se obtiene en la tabla de la distribución normal tipificada (tabla IV).
- $\frac{\sigma}{\sqrt{n}}$  Es la desviación típica de la distribución muestral de la media, es decir, el error típico de la media.
- $\sigma$  es la desviación típica de la población que es conocida.
- $n$  es el tamaño de la muestra.

A partir de esta ecuación deducimos tanto el tamaño de la muestra como los límites del intervalo de confianza.

El tamaño de la muestra se obtiene despejando  $n$  de la ecuación:

$$n = \frac{z_{1-\alpha/2}^2 \sigma^2}{E_{\text{máx}}^2}$$

vemos que  $n$  depende de:

- La desviación típica de la población.
- El nivel de confianza.
- El error de estimación máximo.

Los *límites inferior ( $L_i$ ) y superior ( $L_s$ )* se obtienen a partir del  $E_{\text{máx}}$ :

$$L_i = X - E_{\text{máx}} \quad // \quad L_i = X - z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}$$

$$L_s = X + E_{\text{máx}} \quad // \quad L_s = X + z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}$$

El n.c. o **probabilidad  $1 - \alpha$**  significa que si extrajésemos todas las muestras posibles de una población, calculásemos la media en cada una de ellas y el intervalo de confianza, una proporción  $1 - \alpha$  de todos los intervalos de confianza contendrá la media poblacional y una proporción  $\alpha$  no lo contendrá.

### *Tamaño de la muestra*

Interesa que un intervalo sea lo más estrecho posible y con alta probabilidad. A mayor nivel de confianza mayor es el error de estimación máximo, por lo que más amplio será el intervalo y menos precisa será la estimación. Una forma de mantener y reducir el error de estimación máximo dado y aumentar el n.c., es aumentando  $n$ .

Otro factor que interviene es la variabilidad de la variable, cuanto mayor sea la desviación típica de la población, mayor debe ser n para alcanzar una misma precisión.

Para calcular el tamaño de la muestra desconociendo  $\sigma$ , hay que sustituir en la ecuación, la desviación típica por la cuasidesviación típica ( $S_{n-1}$ ) y  $z_{1-\alpha/2}$  por  $t_{n-1, 1-\alpha/2}$  (tabla VI).

### Aplicaciones

Los pasos para aplicar un intervalo de confianza son los siguientes:

- Establecer un error de estimación máximo para un nivel de confianza  $1 - \alpha$ .
- Obtener el tamaño de la muestra n para el error de estimación máximo especificado.
- Extraer una muestra aleatoria de tamaño n y medir la variable.
- Calcular el estadístico (es estimador del parámetro) con las medidas obtenidas.
- Calcular los límites del intervalo de confianza.

### Intervalo de confianza para la media

#### Límites de los intervalos de confianza y supuestos para la estimación de la media:

Supuestos	Límites del intervalo de confianza para la media
<ul style="list-style-type: none"> <li>• Muestreo aleatorio simple.</li> <li>• <math>\sigma</math> conocida.</li> <li>• Distribución normal o no normal con <math>n \geq 30</math> (aprox. a la normal).</li> </ul>	$L_i = \bar{X} - z_{1-\alpha/2} \sigma_{\bar{x}} \quad L_s = \bar{X} + z_{1-\alpha/2} \sigma_{\bar{x}}$ $z_{1-\alpha/2} \rightarrow \text{Tabla IV}$ $\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}}$
<ul style="list-style-type: none"> <li>• Muestreo aleatorio simple.</li> <li>• <math>\sigma</math> desconocida.</li> <li>• Distribución normal.</li> <li>• <math>n &lt; 30^5</math>.</li> </ul>	$L_i = \bar{X} - t_{n-1, 1-\alpha/2} \hat{S}_{\bar{x}} \quad L_s = \bar{X} + t_{n-1, 1-\alpha/2} \hat{S}_{\bar{x}}$ $t_{n-1, 1-\alpha/2} \rightarrow \text{Tabla VI}$ $\hat{S}_{\bar{x}} = \frac{S_{n-1}}{\sqrt{n}}$
<ul style="list-style-type: none"> <li>• Muestreo aleatorio simple.</li> <li>• <math>\sigma</math> desconocida.</li> <li>• Distribución normal o no normal con <math>n \geq 30</math> (aprox. a la normal).</li> </ul>	$L_i = \bar{X} - z_{1-\alpha/2} \hat{S}_{\bar{x}} \quad L_s = \bar{X} + z_{1-\alpha/2} \hat{S}_{\bar{x}}$ $z_{1-\alpha/2} \hat{S}_{\bar{x}} \rightarrow \text{Tabla IV}$ $\hat{S}_{\bar{x}} = \frac{S_{n-1}}{\sqrt{n}}$

$S_{n-1}$ es la cuasidesviación típica calculada en la muestra.
---

### *Intervalo de confianza para la proporción*

El error de estimación máximo de la proporción es:

$$E_{\text{máx}} = z_{1-\alpha/2} \sqrt{\frac{\pi(1-\pi)}{n}}$$

donde:

- $z_{1-\alpha/2}$  es función del nivel de confianza  $1 - \alpha$  (tabla IV).
- $\sqrt{\frac{\pi(1-\pi)}{n}}$  es el error típico de la proporción:  $\sigma_p$ .
- $\pi$  es la proporción de la población que no es conocida.
- $n$  es el tamaño de la muestra y se debe cumplir  $n\pi(1-\pi) \geq 5$  para la aproximación a la normal.

Los límites inferior y superior del intervalo de confianza se obtienen a partir del error de estimación máximo. Como desconocemos  $\pi$ , que es lo que precisamente queremos estimar, operamos con la proporción muestral  $P$ . Así, si en  $E_{\text{máx}}$  sustituimos  $\pi$  por la proporción muestral  $P$ , los límites inferior y superior del intervalo de confianza son:

$$L_i = P - z_{1-\alpha/2} \sqrt{\frac{P(1-P)}{n}} = P - E_{\text{máx}}$$

$$L_s = P + z_{1-\alpha/2} \sqrt{\frac{P(1-P)}{n}} = P + E_{\text{máx}}$$

Y la probabilidad de obtener un intervalo de confianza que contenga al parámetro  $\pi$  es:

$$P \left[ P - z_{1-\alpha/2} \sqrt{\frac{P(1-P)}{n}} \leq \pi \leq P + z_{1-\alpha/2} \sqrt{\frac{P(1-P)}{n}} \right] = 1 - \alpha$$