

# Intervalos de confianza para los parámetros de una distribución normal

- ▶ Tenemos muestras de una población Normal  $N(\mu, \sigma)$
- ▶ Veremos como estimar *rangos de confianza* para estos parámetros en 4 casos distintos
  1. rango para  $\mu$ , con  $\sigma$  conocido
  2. rango para  $\mu$ , con  $\sigma$  desconocido
  3. rango para  $\sigma$ , con  $\mu$  conocido
  4. rango para  $\sigma$ , con  $\mu$  desconocido

- ▶ Construimos función de los datos y de los parámetros
  - ▶  $P(a \leq Y(\underline{x}, \mu, \sigma) \leq b) = \gamma$
- ▶ Estudiar la distribución de la nueva variable aleatoria  $Y$  (¿es un estadístico?) para poder calcular los límites de confianza  $a, b$ .
  - ▶  $\int_a^b f_Y(y) dy = \gamma = F_Y(b) - F_Y(a)$
- ▶  $a, b$  *no son únicos*. Límites centrales, a una cola, a dos colas, . . .
- ▶ *Monte Carlo* para generar números aleatorios gaussianos con distribución  $N(\mu = 10, \sigma = 2)$ 
  - ▶ Una muestra es una terna  $\{x_1, x_2, x_3\}_i$ .
  - ▶  $N = 1000$  experimentos.
  - ▶ Cada medición de la terna es independiente de las otras.
  - ▶ Las repeticiones son independientes.
  - ▶ Muestreos *con sustitución*.

## Intervalo de confianza para $\mu$ , con $\sigma$ conocido


- ▶  $P(a \leq Y(\underline{x}, \mu, \sigma) \leq b) = \gamma \rightarrow P(L(\underline{x}, \sigma) \leq \mu \leq U(\underline{x}, \sigma)) = \gamma$
- ▶  $I = [L(\underline{x}, \sigma), U(\underline{x}, \sigma)]$
- ▶  $\sigma$  puede formar parte de los estadísticos, en este caso!

## Intervalo para $\mu$ , con $\sigma$ conocido

- ▶ La función natural para estimar  $\mu$  es la media:  $Y = \bar{x} = \frac{1}{n} \sum_{j=1}^n x_j$ .
- ▶ Éste estadístico tiene distribución  $N(\mu, \sigma/\sqrt{n})$ , de modo que la variable

$$U = \frac{\bar{x} - \mu}{\sigma/\sqrt{n}}$$

tiene distribución  $N(0, 1)$



## Intervalo para $\mu$ , con $\sigma$ conocido

- ▶ El contenido de probabilidad de una distribución  $N(0, 1)$  entre los límites  $a$  y  $b$  es

$$P\left(a \leq \frac{\bar{x} - \mu}{\sigma/\sqrt{n}} \leq b\right) = \int_a^b N_t(0, 1) dt = 0.95$$

o de modo equivalente

$$P\left(\bar{x} + a\frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{x} + b\frac{\sigma}{\sqrt{n}}\right) = 0.95$$

- ▶ Intervalo central  $a = -b \approx 2$  (por ser standard normal!).

## Intervalo para $\mu$ , con $\sigma$ conocido

- ▶ Antes de la medición, existe un 95% probabilidad que el intervalo aleatorio

$$I = \left[ \bar{x} + a \frac{\sigma}{\sqrt{n}}; \bar{x} + b \frac{\sigma}{\sqrt{n}} \right]$$

encierre al verdadero valor  $\mu$ .

- ▶ El intervalo es aleatorio, pues depende de variables aleatorias.
- ▶ Suceso A = “el intervalo aleatorio encierra al valor real de  $\mu$ ”;
  - ▶  $P(A) = 0.95$
- ▶ De la simulación resulta que de  $N = 1000$  realizaciones del experimento, en  $\sim 960$  el verdadero valor  $\mu$  está dentro del intervalo  $I$ .
  - ▶ ¿Es razonable?
- ▶ Llamemos “éxito” a que  $\mu$  esté contenido en el intervalo  $I$ .
- ▶ El número de éxitos es una variable aleatoria que tiene distribución binomial  $B_{\gamma}(N = 1000, p = \gamma = 0.95)$  con media:  $N\gamma = 950$  y varianza:  $N\gamma(1 - \gamma) \approx (6.892)^2$ .

Intervalo de confianza para  $\mu$ , con  $\sigma$   
desconocido

## Intervalo para $\mu$ , con $\sigma$ desconocido

- ▶  $\sigma$  es ahora una incógnita más del problema.
- ▶ La estimación de  $\mu$  debe realizarse en ausencia del dato  $\sigma$ .
- ▶ ¿Podemos usar

$$s^2 = \frac{1}{n-1} \sum_{j=1}^n (x_j - \bar{x})^2$$

en reemplazo de  $\sigma^2$ ?

$$\frac{\bar{x} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1) \longrightarrow \frac{\bar{x} - \mu}{\sqrt{s^2}/\sqrt{n}} \sim ???$$

- ▶  $U = \frac{\bar{x} - \mu}{\sigma/\sqrt{n}}$  tiene distribución  $N(0, 1)$
- ▶  $W = \frac{(n-1)s^2}{\sigma^2}$  está distribuida como  $\chi_{(n-1)}^2$  (pg 136 Frodesen).
- ▶ la variable cociente

$$Z = \frac{U}{\sqrt{W/(n-1)}} = \frac{\bar{x} - \mu}{\sqrt{s^2}/\sqrt{n}}$$


por construcción elimina el parámetro desconocido  $\sigma$  y deja como único parámetro incógnita el  $\mu$ .

## Intervalo para $\mu$ , con $\sigma$ desconocido

- ▶ la variable cociente

$$Z = \frac{U}{\sqrt{W/(n-1)}} = \frac{N(0, 1)}{\sqrt{\chi^2_{(n-1)}/(n-1)}}$$

tiene distribución **t-Student** con  $n-1$  grados de libertad. (pg 141, Frodesen)




$$f_t(t; \nu) = \frac{\Gamma((\nu+1)/2)}{\sqrt{\pi\nu}\Gamma(\nu/2)} \frac{1}{\left(1 + \frac{t^2}{\nu}\right)^{1/2(\nu+1)}}$$

- ▶  $\nu = 1$  da Cauchy
- ▶  $\nu \rightarrow \infty$  da Normal

## Intervalo para $\mu$ , con $\sigma$ desconocido

- ▶ Con esta variable aleatoria el contenido de probabilidad alcanza el grado de confianza  $\gamma = 0.95$  para

$$P\left(a \leq \frac{\bar{x} - \mu}{\sqrt{s^2}/\sqrt{n}} \leq b\right) = 0.95$$



## Intervalo para $\mu$ , con $\sigma$ desconocido

- ▶ Como  $t_{(2)}$  es simétrica respecto de 0 podemos pedir la relación  $a = -b$  y así

$$P\left(-b \leq \frac{\bar{x} - \mu}{\sqrt{s^2}/\sqrt{n}} \leq b\right) = \int_{-b}^b t_{(2)}(t') dt' = F(b; 2) - F(-b; 2) = 0.95$$

- ▶  $F(-b; 2) = 1 - F(b; 2)$ , implica  $F(b; 2) = (1 + 0.95)/2$ , para t-Student con 2 grados de libertad corresponde a  $b = 4.303$ .

▶

$$P\left(\bar{x} - 4.303 \frac{\sqrt{s^2}}{\sqrt{n}} \leq \mu \leq \bar{x} + 4.303 \frac{\sqrt{s^2}}{\sqrt{n}}\right) = 0.95$$

existe una probabilidad 0.95 de que el intervalo


$$\left[ \bar{x} - 4.303 \frac{\sqrt{s^2}}{\sqrt{n}}; \bar{x} + 4.303 \frac{\sqrt{s^2}}{\sqrt{n}} \right]$$

incluya al verdadero valor de  $\mu$ . Del valor esperado 950 el experimento aleatorio de  $N = 1000$  ternas dio 961 en este caso dentro de la fluctuación estadística de  $\sim 2$  desviaciones estándar respecto de la media ( $950 \pm 6.89$ ).

Intervalo de confianza para  $\sigma$ , con  $\mu$   
conocido

## Intervalo para $\sigma^2$ , con $\mu$ conocido

- ▶ Podemos probar con  $S^2 = \frac{1}{n} \sum_{j=1}^n (x_j - \mu)^2$ , que es un estimador no sesgado de  $\sigma^2$ .
- ▶ Pero no queremos estimar  $\sigma^2$ , sino construir un intervalo para  $\sigma^2$ .
- ▶ Probemos mejor con:  $V = \frac{n}{\sigma^2} S^2 = \sum_{j=1}^n \left( \frac{x_j - \mu}{\sigma} \right)^2 \sim \chi^2_{(n)}$



## Intervalo para $\sigma^2$ , con $\mu$ conocido

$$P\left(a \leq \frac{nS^2}{\sigma^2} \leq b\right) = P\left(\frac{nS^2}{b} \leq \sigma^2 \leq \frac{nS^2}{a}\right) = 0.95$$

- ▶ Infinitos posibles intervalos  $[a; b]$  que dan una probabilidad 0.95 de contener a  $\sigma^2$ . Intervalo central (¿puede ser  $a = -b$ ?)

$$P\left(\chi_{(3)}^2 < a\right) = P\left(\chi_{(3)}^2 > b\right) = (1 - 0.95)/2 = 0.025$$

- ▶ Por tabla  $a = 0.216$  y  $b = 9.348$ . Por lo tanto el intervalo aleatorio de confianza para 0.95 es

$$I = \left[ \frac{nS^2}{9.348}; \frac{nS^2}{0.216} \right]$$

- ▶ De las 1000 corridas aleatorias sólo 940 contuvieron a  $\sigma^2$  dentro del intervalo, de nuevo consistente considerando la fluctuación binomial estimada ( $950 \pm 6.89$ ).


Intervalo de confianza para  $\sigma$ , con  $\mu$   
desconocido

## Intervalo para $\sigma^2$ , con $\mu$ desconocido

- ▶ Debemos eliminar el parámetro  $\mu$  de la variable aleatoria a considerar.
- ▶ Podemos probar con  $s^2 = \frac{1}{n-1} \sum_{j=1}^n (x_j - \bar{x})^2$ , estimador no sesgado de  $\sigma^2$ .

- ▶ Transformémoslo en una variable de distribución conocida:

$$W = \frac{(n-1)s^2}{\sigma^2} = \sum_{j=1}^n \left( \frac{x_j - \bar{x}}{\sigma} \right)^2 \text{ que tiene distribución } \chi_{(n-1)}^2.$$



## Intervalo para $\sigma^2$ , con $\mu$ desconocido

$$P\left(a \leq \frac{(n-1)s^2}{\sigma^2} \leq b\right) = P\left(\frac{(n-1)s^2}{b} \leq \sigma^2 \leq \frac{(n-1)s^2}{a}\right) = 0.95$$

- Utilizando un intervalo central,

$$P\left(\chi_{(2)}^2 < a\right) = P\left(\chi_{(2)}^2 > b\right) = (1 - 0.95)/2 = 0.025$$

por tabla corresponde a  $a = 0.0506$  y  $b = 7.378$ :

$$I = \left[ \frac{(n-1)s^2}{7.378}; \frac{(n-1)s^2}{0.0506} \right]$$

- En un caso de las 1000 corridas aleatorias sólo 947 dieron a  $\sigma^2$  dentro del intervalo, de nuevo consistente considerando la fluctuación binomial ( $950 \pm 6.89$ ).

## Comentario general

- ▶ En los cuatro casos, la probabilidad de que el intervalo aleatorio encierre al valor real del parámetro la fijamos en  $\gamma = 0.95$ .
- ▶ La variable aleatoria:  $Y$ ="número de veces el intervalo aleatorio encierra al valor real del parámetro", tiene distribución binomial  $B_Y(N, \gamma)$ .
- ▶ Esto ocurre bajo la *interpretación frecuentista* de la probabilidad.
- ▶ Por lo tanto,  $(1 - \gamma)100\%$  de las veces, el intervalo no contendrá al verdadero valor del parámetro desconocido que queremos estimar.