

Estadística I

Tema 7: Intervalos de Confianza

UNA POBLACIÓN NORMAL: ICs para la MEDIA

1) En este ejercicio con intervalos de confianza para la media muestral μ se necesita la instalación del paquete `RcmdrPlugin.TeachingDemos`. Cargamos el paquete mediante el menú de Rcmdr:

Herramientas → Cargar plug-in(s) de Rcmdr

En la ventana de diálogo, elige `RcmdrPlugin.TeachingDemos`. R preguntará sobre el permiso para rearrancar Rcmdr (*¿Reiniciar ahora?*), de modo que se pueda añadir la opción de **Demostraciones** a su menú principal.

Para ver cómo funcionan los intervalos de de confianza para la media poblacional:

- a) Genera $I = 50$ muestras de tamaño $n = 9$ de una distribución normal $N(\mu = 100, \sigma^2 = 4^2)$ y para cada una de las I muestras construye un intervalo de confianza al 95% para μ (se supone que μ es desconocida) asumiendo que la desviación estándar poblacional es conocida:

Demostraciones → Intervalos de confianza para la media...

En la ventana de diálogo rellena los campos **Population mean**, **Population standard deviation**, **Sample size**, **Number of samples**, **Confidence level** con 100, 4, 9, 50, 0.95, respectivamente. Marca el campo **Population standard deviation known**. Pulsa OK.

Con un nivel de confianza del 95%, en teoría, sólo el 95% de los I intervalos de confianza cubrirán μ y los restantes 5% no lo harán.

¿Cómo funciona esta regla en la práctica? es decir, ¿cuál es el porcentaje de los $I = 50$ intervalos de confianza que no incluyen a μ ?

¿Son simétricos los intervalos de confianza respecto a las correspondientes medias muestrales?

- b) Abre una ventana gráfica nueva (ejecuta `x11()` en la ventana **Ventana de Instrucciones**). Repite a), asumiendo que la desviación estándar poblacional σ es desconocida.
¿Cuál es la distribución muestral de \bar{x} en ese caso?
- c) Abre una nueva ventana gráfica. Repite a) para $n = 100$ y con el resto haz lo mismo.
¿Los intervalos de confianza son más largos o más cortos comparados con los del apartado a)? ¿Por qué?
- d) Abre una nueva ventana gráfica. Repite a) para $\sigma = 1$ y con el resto haz lo mismo.
¿Los intervalos de confianza son más largos o más cortos comparados con los del apartado a)? ¿Por qué?
- e) Abre una nueva ventana gráfica. Repite a) para el **Confidence level** del 99% y con el resto haz lo mismo.
¿Los intervalos de confianza son más largos o más cortos comparados con los del apartado a)? ¿Por qué?

2) Carga el conjunto de datos `trees` del paquete `datasets` ejecutando:

```
data(trees, package = "datasets")
```

Además, si escribes en la **Ventana de Instrucciones**:

```
attach(trees)
```

Te puedes referir a las variables de este conjunto de datos por sus nombres sin necesidad de escribir `trees$` antes del nombre.

La variable de interés es `Height`.

a) Comprueba la suposición de normalidad de la población de `Height` examinando el histograma de la muestra:

```
hist(Height)
```

b) Construye un intervalo de confianza al 90% para μ (media poblacional de la variable `height`):

```
t.test(x=Height, alternative="two.sided", conf.level=0.90)
```

(Esta función de R se aplica fundamentalmente en el “Tema 8: Contrastes de Hipótesis”, pero la estudiaremos también en el “Tema 7”).

Se obtendrá (74.05764, 77.94236). Interpreta el resultado.

c) Indica cuáles son las suposiciones necesarias para que sean legítimos los intervalos de confianza en b).

UNA POBLACIÓN NORMAL: ICs para la VARIANZA

3) En este ejercicio se harán gráficos similares a los del problema 1) (donde se usó el paquete `Teaching Demos`), aunque calculando los intervalos de confianza para σ^2 .

Supongamos que $X \sim N(\mu = 0, \sigma^2 = 3^2)$.

Generamos $I = 50$ muestras de X , cada una con $n = 25$ observaciones (guardamos los datos como una matriz I por n , donde las muestras aparecen en las filas), y calculamos un intervalo de confianza al 95% para σ^2 (suponiendo que es desconocida) para cada muestra:

Distribuciones → Distribuciones continuas → Distribución normal → Muestra de una distribución normal...

En la ventana de diálogo, **Introducir el nombre del conjunto de datos**: Ponemos como nombre `Muestras.normales`. Ajustamos los parámetros de la distribución si fuera necesario. En el campo **Número de muestras** ponemos '50' y en el de **Número de observaciones** '25', y marcamos el campo **Desviación estándar de cada muestra**. El conjunto activo será, entonces, `Muestras.normales`. Si marcamos en **Visualizar conjunto de datos** se ven las I desviaciones muestrales estándar en la última columna de la hoja de datos etiquetada como `sd`.

a) Calcula los cuantiles $\alpha/2$ y $(1 - \alpha/2)$ de la distribución chi-cuadrada con $df = n - 1 = 24$ (revisa el Laboratorio anterior que tiene instrucciones similares):

Distribuciones → Distribuciones continuas → Distribución Chi-cuadrado → Cuantiles Chi-cuadrado

En la ventana de diálogo, especifica las **Probabilidades** como `c(0.025,0.975)`, los **Grados de libertad** como 24, y marca la **Cola derecha**.

Debes obtener 39.36 y 12.40, respectivamente.

b) Calcula los extremos inferiores de los intervalos:

Datos → Modificar variables del conjunto de datos activo → Calcular una nueva variable

En la ventana de diálogo, selecciona una de las **Variables actuales** (pulsando con el ratón). Introduce el **Nombre de la nueva variable**, por ejemplo, `ext.inferior` e introduce la **Expresión a calcular** como `24*sd^2/39.36`. Pulsa OK.

c) Calcula el extremo superior: Introduce la **Nombre de la nueva variable**, por ejemplo, `ext.superior` e introduce la **Expresión a calcular** como `24*sd^2/12.40`

Nota: Los pasos a)-c) se pueden hacer también ejecutando el siguiente código en la **Ventana de Instrucciones**:

```
ext.inferior.denom=qchisq(p=0.025,df=24,lower.tail=FALSE)
ext.superior.denom=qchisq(p=0.975,df=24,lower.tail=FALSE)
Muestras.normales$ext.inferior=with(Muestras.normales,24*sd^2/ext.inferior.denom)
Muestras.normales$ext.superior=with(Muestras.normales,24*sd^2/ext.superior.denom)
```

Después de esto, el conjunto de datos activo tendrá dos columnas más cada una de longitud I denominada `ext.inferior` y `ext.superior`.

Para dibujar los intervalos de confianza, ejecuta el siguiente código en la **Ventana de Instrucciones**:

```
I=50
sigma=3
Index=1:I
xlim=c(0,sigma^2+40)
ylim=c(1,I)
plot(x=xlim,y=ylim,type="n",xlab=expression(sigma^2),ylab="Index")
segments(Muestras.normales$ext.inferior,Index,
Muestras.normales$ext.superior,Index)
abline(v=sigma^2,col="red")
```

Con un nivel de confianza del 95%, en teoría, sólo el 95% de los I intervalos de confianza recubren a σ^2 y el restante 5% no lo hace.

¿Cómo funciona esta regla en la práctica? es decir, ¿qué porcentaje de los $I = 50$ intervalos de confianza no incluyen a σ^2 ?

4) Usa el mismo conjunto de datos que en 2).

a) Construye un intervalo de confianza al 90% para σ^2 (varianza poblacional de la variable **Height**):

```
n=length(Height)
sample.var=var(Height)
ext.inferior.denom=qchisq(p=0.05,df=n-1,lower.tail=FALSE)
ext.superior.denom=qchisq(p=0.95,df=n-1,lower.tail=FALSE)
c((n-1)*sample.var/ext.inferior.denom,
(n-1)*sample.var/ext.superior.denom)
```

Interpreta.

- b) Construye un intervalo de confianza al 95% para σ (desviación estándar poblacional de la variable **Height**):

```
n=length(Height)
sample.var=var(Height)
ext.inferior.denom=qchisq(p=0.025,df=n-1,lower.tail=FALSE)
ext.superior.denom=qchisq(p=0.975,df=n-1,lower.tail=FALSE)
c(sqrt((n-1)*sample.var/ext.inferior.denom),
sqrt((n-1)*sample.var/ext.superior.denom))
```

Interpreta.

DOS POBLACIONES NORMALES: ICs para la DIFERENCIA entre DOS MEDIAS y para el COCIENTE (RAZÓN) de las VARIANZAS

- 5) Genera dos muestras aleatorias independientes de $X_1 \sim N(\mu_1 = 5, \sigma_1^2 = 4^2)$ de tamaño $n_1 = 15$ y de $X_2 \sim N(\mu_2 = 5, \sigma_2^2 = 5^2)$ de tamaño $n_2 = 20$ ejecutando en la **Ventana de Instrucciones**:

```
x1=rnorm(n=15,mean=5,sd=4)
x2=rnorm(n=20,mean=5,sd=5)
```

- a) Calcula un intervalo de confianza al 90% para $\mu_1 - \mu_2$ asumiendo que las varianzas poblacionales son desconocidas y diferentes:

```
t.test(x=x1, y=x2, alternative = "two.sided", conf.level = 0.9,
var.equal=FALSE)
```

Interpreta.

- b) Calcula un intervalo de confianza al 85% para σ_1^2/σ_2^2 :

```
var.test(x=x1, y=x2, alternative="two.sided", conf.level=0.85)
```

Interpreta.

- 6) Carga los siguientes datos sobre tasas de inflación en países desarrollados (X_1) y en vías de desarrollo (X_2) en la **Ventana de Instrucciones** ejecutando:

```
developed=c(3.99, 4.07, 3.70, 1.79, 5.30, 3.47, 2.39, 3.33, 4.14, 3.11)
developing=c(4.73, 5.01, 5.07, 4.66, 4.49, 4.00, 4.33, 5.14, 3.15, 3.46)
```

- a) Comprueba la normalidad de ambas poblaciones examinando los histogramas de las muestras (usamos el comando `par(mfrow=c(1,2))` para dibujar dos figuras en una misma ventana gráfica):

```
par(mfrow=c(1,2))
hist(developed,breaks=2)
hist(developing,breaks=2)
```

- b) Calcula un intervalo de confianza al 95% para σ_1^2/σ_2^2 :

```
var.test(x=developed,y=developing,alternative="two.sided",conf.level=0.95)
```

Interpreta.

Nota: Si el valor igual a 1 pertenece a este intervalo, se concluye que σ_1^2/σ_2^2 es igual a 1 (con una confianza del 95%). Así, $\sigma_1^2 = \sigma_2^2$ y se dice que las dos poblaciones tienen varianzas

iguales (Leer “Tema 8” para más detalles). En caso contrario, se dice que las varianzas poblacionales son diferentes (con una confianza del 95%).

- c) Calcula un intervalo de confianza al 95% para $\mu_1 - \mu_2$, teniendo en cuenta los resultados de la parte a) (fija `var.equal` en `TRUE` si las varianzas poblacionales son iguales y `FALSE` en otro caso):

```
t.test(x=developed, y=developing, alternative="two.sided",
conf.level=0.95, var.equal=...)
```

Interpreta.

- d) Indica cuáles son las suposiciones necesarias para que sean legítimos los intervalos de confianza en b) y en c).

MUESTRAS GRANDES: UNA POBLACIÓN (ICs para la PROPORCIÓN), DOS POBLACIONES (ICs para la DIFERENCIA de las PROPORCIONES)

7) Genera dos muestras aleatorias independientes de $X_1 \sim \text{Bernoulli}(p_1 = 0.3)$ de tamaño $n_1 = 40$ y de $X_2 \sim \text{Bernoulli}(p_2 = 0.4)$ de tamaño $n_2 = 50$ ejecutando en la **Ventana de Instrucciones:**

```
x1=sample(x=c(0,1),size=40,replace=TRUE,prob=c(0.7,0.3))
```

```
x2=sample(x=c(0,1),size=50,replace=TRUE,prob=c(0.6,0.4))
```

- a) Calcula un intervalo de confianza al 90% para p_1 (sin corrección de continuidad, `correct=FALSE`):

```
prop.test(sum(x1), n=length(x1), p=NULL, alternative="two.sided",
conf.level=0.90, correct=FALSE)
```

Alternativamente,

```
z.test(x=x1, stdev=sqrt(mean(x1)*(1-mean(x1))), alternative="two.sided",
conf.level=0.90)
```

Interpreta.

- b) Calcula un intervalo de confianza al 95% para $p_1 - p_2$:

```
prop.test(c(sum(x1),sum(x2)),n=c(length(x1),length(x2)), p = NULL,
alternative = "two.sided",conf.level = 0.95, correct = FALSE)
```

Alternativamente,

```
n1=40
```

```
n2=50
```

```
p1=mean(x1)
```

```
p2=mean(x2)
```

```
v1=(p1*(1-p1))/n1
```

```
v2=(p2*(1-p2))/n2
```

```
z=qnorm(p=0.025,lower.tail=FALSE)
```

```
c(p1-p2-z*sqrt(v1+v2),p1-p2+z*sqrt(v1+v2))
```

Interpreta.

- c) ¿Qué teorema permite calcular los intervalos de confianza en a) y b)? ¿Qué condiciones deben cumplir n_1 y n_2 ?