

Inferencia sobre la diferencia de proporciones y el cociente de varianzas

Intervalos de confianza y contraste de hipótesis

Grado Biología sanitaria

M. Marvá

e-mail: marcos.marva@uah.es

Unidad docente de Matemáticas, Universidad de Alcalá

20 de noviembre de 2017

Inferencia: diferencia de proporciones

Queremos responder preguntas tipo: el escarabajo tigre puede tener distintas coloraciones



Se toman muestras

- De los 500 escarabajos de Providence, Rhode Island, 95 eran negros
 - De los 112 escarabajos en Aqueduct, Nueva York, 17 eran negros
- 1 **Intervalo de confianza** ¿En cuánto difiere la **proporción poblacional** de individuos negros en cada colonia?
 - 2 **Contrastar hipótesis** sobre la proporción de individuos negros
 - ¿son **significativamente** diferentes? (bilateral)
 - ¿es **significativamente** mayor en una de las colonias? (unilateral)

Inferencia: diferencia de proporciones

Distribución muestral de la diferencia de proporciones

Dos poblaciones cuyos individuos pueden presentar (éxito) o no (fracaso) una característica determinada

- 1 Dos muestras de tamaños n_1 y n_2
- 2 Proporciones muestrales \hat{p}_i
- 3 Además, por el Teorema del límite central, si

$$n_1 > 30, \quad n_2 > 30, \quad n_1 \cdot \hat{p}_1 > 5, \quad n_1 \cdot \hat{q}_1 > 5, \quad n_2 \cdot \hat{p}_2 > 5, \quad n_2 \cdot \hat{q}_2 > 5$$

$$\text{entonces, } \hat{p}_1 \sim N\left(p_1, \sqrt{\frac{\hat{p}_1 \cdot \hat{q}_1}{n_1}}\right) \quad \text{y} \quad \hat{p}_2 \sim N\left(p_2, \sqrt{\frac{\hat{p}_2 \cdot \hat{q}_2}{n_2}}\right)$$

¿Cómo se comporta la suma (o resta) de v.a. normales?

$$\hat{p}_1 - \hat{p}_2 \sim N\left(p_1 - p_2, \sqrt{\frac{\hat{p}_1 \cdot \hat{q}_1}{n_1} + \frac{\hat{p}_2 \cdot \hat{q}_2}{n_2}}\right)$$

Ahora todo es análogo al caso de una población.

Inferencia: diferencia de proporciones

Ejemplo: el de los escarabajo tigre.

- De los 500 escarabajos de Providence, Rhode Island, 95 eran negros
- De los 112 escarabajos en Aqueduct, Nueva York, 17 eran negros

Se pide

- 1 Calcula e interpreta el i.c. para la diferencia de proporciones, $\alpha = 0.1$
- 2 A la vista de los valores muestrales,

$$\hat{p}_1 = \frac{95}{500} = 0.19 \quad \hat{p}_2 = \frac{17}{112} = 0.1517857$$

Establece las hipótesis adecuadas sobre las proporciones de escarabajos negros en cada población y contrástalas

Inferencia: diferencia de proporciones

Ejemplo: el escarabajo tigre.

- 1 Usamos las plantillas de intervalos de confianza

$$(-0.025, 0.101)$$

INTERPRETACION

- 2 Usamos las plantillas de contraste de hipótesis para contrastar

$$H_0 : p_1 = p_2 \qquad H_1 : p_1 \neq p_2$$

y también

$$H_0 : p_1 \leq p_2 \qquad H_1 : p_1 > p_2$$

Inferencia sobre dos poblaciones: varianzas

Queremos responder preguntas tipo: estudiamos la longitud del caparazón de cangrejos de la especie *Leptograpsus variegatus* agrupados según su color (azul o naranja).



Se obtienen sendas muestras de longitudes \bar{X}_1 y \bar{X}_2 ;

- 1 **Intervalo de confianza** ¿Es posible comparar lo agrupados que están las longitudes en cada subgrupo? ¿en cuál hay más variabilidad?
- 2 **Contraste de hipótesis** Sobre las longitudes, vista la muestra,
 - ¿Son diferentes **a nivel poblacional**?
 - ¿Hay más dispersión en uno de los subgrupos **a nivel poblacional**?

Inferencia sobre dos poblaciones: varianzas

Ejemplo: Supongamos que $\sigma_1^2 = \frac{1}{1000}$, $\sigma_2^2 = \frac{1}{1000000}$. Entonces

$$\sigma_1^2 - \sigma_2^2 = 0.000999, \quad \text{pero} \quad \frac{\sigma_1^2}{\sigma_2^2} = 1000.$$

- La diferencia $\sigma_1^2 - \sigma_2^2$ es *sensible a la escala*
- El cociente no tiene ese problema

Si el cociente de dos números es cercano a uno, podemos asegurar que los dos números son realmente parecidos, con independencia de la escala de medida.

A menudo, lo más útil es usar:

- La **diferencia** para comparar medidas de centralización (medias, proporciones, medianas, etc.): **en cuántas unidades difieren**
- El **cociente** para comparar medidas de dispersión (varianzas, recorridos intercuartílicos, etc) **cuántas veces más disperso**

Inferencia sobre dos poblaciones: varianzas

Dadas dos poblaciones normales y muestras independientes de tamaños n_1 y n_2 , el **intervalo de confianza al nivel $nc = (1 - \alpha)$ para el cociente de varianzas $\frac{\sigma_1^2}{\sigma_2^2}$** es:

$$\left(\frac{s_1^2}{s_2^2} \cdot \frac{1}{F_{n_1-1, n_2-1; \alpha/2}}, \frac{s_1^2}{s_2^2} \cdot \frac{1}{F_{n_1-1, n_2-1; 1-\alpha/2}} \right)$$

con $F_{n_1-1, n_2-1, \alpha}$ el valor crítico α de la F_{n_1-1, n_2-1} .

Ejemplo: dadas dos muestras de poblaciones normales con, $n_1 = 55$, $n_2 = 47$, $s_1 = 3$, $s_2 = 4.1$ calcular el IC al nc 95 % para el cociente de las varianzas

$$IC_{\sigma_1^2/\sigma_2^2} = \left(\frac{3}{4.1} \cdot \frac{1}{f_{54,46;0.025}}, \frac{3}{4.1} \cdot \frac{1}{f_{54,46;0.975}} \right) = (0.303, 0.93)$$

donde:

$$f_{54,46;0.025} = \text{qf}(0.975, \text{df1} = 54, \text{df2} = 46) = 1.7665018$$

$$f_{54,46;0.975} = \text{qf}(0.025, \text{df1} = 54, \text{df2} = 46) = 0.5733775$$

INTREPRETACION

Ejemplo: Para las especies que aparecen en el fichero `crabs` de la librería `asbio` de R se quiere estimar la relación entre la variabilidad de la longitud del lóbulo frontal (FL) en cada una de las especies analizadas (naranja y azul). `aggregate(crabs$FL ~ crabs$sp, FUN = sd)`

```
crabs$sp crabs$FL
      B 3.019610
      O 3.275575
```

Si se toma otra muestra, ¿qué se puede esperar? usa un nivel de confianza del 95 %

- Cálculos con la plantilla.
- INTERPRETACION


Inferencia sobre dos poblaciones: varianzas

Contraste sobre el cociente de varianzas con nivel de significación α .

Región de rechazo: se usa el estadístico

$$Y = \frac{s_1^2}{s_2^2}$$


(a) $H_0 : \sigma_1^2 \leq \sigma_2^2$ $H_1 : \sigma_1^2 > \sigma_2^2$. Región de rechazo: $Y > F_{n_1-1, n_2-1, \alpha}$



(b) $H_0 : \sigma^2 \geq \sigma_0^2$ $H_1 : \sigma^2 < \sigma_0^2$. Región de rechazo: $Y < F_{n_1-1, n_2-1, 1-\alpha}$



(c) $H_0 : \sigma^2 = \sigma_0^2$ $H_1 : \sigma^2 \neq \sigma_0^2$. Región de rechazo: $Y \notin (F_{n_1-1, n_2-1, 1-\alpha/2}, F_{n_1-1, n_2-1, \alpha/2})$



Ejemplo 1: dadas dos muestras de poblaciones normales con, $n_1 = 55$, $n_2 = 47$, $s_1 = 3$, $s_2 = 4.3$ contrasta la hipótesis

$$H_0 : \sigma_1^2 \geq \sigma_2^2 \qquad H_1 : \sigma_1^2 < \sigma_2^2$$

Ejemplo 2: contrasta la igualdad de varianzas en el ejemplo del fichero crabs

Inferencia sobre dos poblaciones: varianzas

El cálculo del **p-valor** es:

(a) $H_0 : \sigma_1^2 \leq \sigma_2^2$ $H_a : \sigma_1^2 > \sigma_2^2$.

p-valor = $P(F_{k_1, k_2} > s_1^2/s_2^2)$ (cola derecha)

(b) $H_0 : \sigma_1^2 \geq \sigma_2^2$ $H_a : \sigma_1^2 < \sigma_2^2$.

p-valor = $P(F_{k_1, k_2} < s_1^2/s_2^2)$ (cola izquierda).

(c) $H_0 : \sigma_1^2 = \sigma_2^2$ $H_a : \sigma_1^2 \neq \sigma_2^2$.

p-valor = $2 \cdot P(F_{k_1, k_2} > s_1^2/s_2^2)$ ¡¡siempre que sea $s_1^2/s_2^2 \geq 1$!! Si se tiene $s_1^2/s_2^2 < 1$, cambiar s_1 por s_2 .