

Intervalos de confianza
Test. de hipótesis

Problema 1 Es una aseguradora, el número de partes recibidas por siniestros en un día sigue una distribución de Poisson. Se desea contrastar las hipótesis
 $H_0: \lambda = 2$ vs $H_1: \lambda = 1$

Análisis, usando el lema de Neyman-Pearson, si existe la mejor región crítica con nivel de significancia del 3%. Para efectuar el contraste, se ha extraído una MAS de 100 días, siendo la media muestral = 1,3.

Sl la receta para aplicar Neyman-Pearson es

- > Imponer la razón de verosimilitudes mayor a cierto k
- > Llegar a cierto estadístico $T \geq k'$ o $T \leq k''$
- > El k' se obtiene de $P(T \geq k' | H_0) = \alpha$, o $P(T \leq k'' | H_0) = \alpha$ (según el punto anterior)

En este caso, la razón de verosimilitud para (x_1, \dots, x_n) será

$$r = \frac{f_n(x_1, \dots, x_n | H_1)}{f_n(x_1, \dots, x_n | H_0)} = \frac{e^{-\lambda_1} (\lambda_1)^{\sum_{i=1}^n x_i} / \prod_{i=1}^n x_i!}{e^{-\lambda_0} (\lambda_0)^{\sum_{i=1}^n x_i} / \prod_{i=1}^n x_i!}$$

$$= e^{-n(\lambda_1 - \lambda_0)} \left(\frac{\lambda_1}{\lambda_0} \right)^{\sum_{i=1}^n x_i} \geq k \quad (*)$$

El estadístico será $T(x_1, \dots, x_n) = \sum_{i=1}^n x_i$. Entonces, aplicando log a (*), los $\vec{x} = (x_1, \dots, x_n) \in \mathcal{X}$ que satisfacen (*) satisfarán

$$-n(\lambda_1 - \lambda_0) + \left(\sum_{i=1}^n x_i \right) \ln(\lambda_1 / \lambda_0) \geq \ln(k)$$

En este caso, $\lambda_1 = 1$, $\lambda_0 = 2 \rightarrow \ln(\lambda_1 / \lambda_0) = \ln(1/2) < 0$

$$\Rightarrow \sum_{i=1}^n x_i \leq \frac{\ln(k) + n(\lambda_1 - \lambda_0)}{\ln(\lambda_1 / \lambda_0)} = k'$$

Si, H_0 : $\lambda = 2$ Región crítica $\lambda \neq 2$

$$R^* = \left\{ (x_1, \dots, x_n) \in \mathbb{R}_+^n \mid \sum_{i=1}^n x_i \leq k' \right\}$$

¿De donde obtenemos k' ? de imponer $P(R^* | H_0) = \alpha$.

solución: $\alpha = 0,03$ $\Rightarrow P\left(\sum_{i=1}^n X_i \leq k' \mid \lambda = 2\right) = \alpha = 0,03$

¿Cómo se encuentra k' ? Se necesita la distribución de $\sum_{i=1}^n X_i$. Como cada $X_i \sim \text{Poisson}(\lambda)$, $\sum_{i=1}^n X_i \sim \text{Poisson}(n\lambda)$.

Ahora, bajo H_0 , $\lambda = 2 \Rightarrow \sum_{i=1}^n X_i \sim \text{Poisson}(2n)$

Como en el ejemplo $n = 100 \Rightarrow \sum_{i=1}^n X_i \sim \text{Poisson}(200)$

Entonces, k' va a ser el primer entero tal que

$$P(\text{Poisson}(200) \leq k') \geq 0,03$$

Calculado por computador, $k' = 174$ ($P(174) = 0,0335$)

$k' = 173$, $P(173) = 0,0283$

Comparando, como $\bar{X}_n = 1,3 = \frac{\sum_{i=1}^n X_i}{n} \Rightarrow \sum_{i=1}^n X_i = 1300$

se tiene que $\sum_{i=1}^n X_i = 1300 > 174$, por lo que no se rechaza $\lambda = 2$.

Problema 2 Sea X_1, \dots, X_n una MAS del modelo uniforme sobre el intervalo $(0, \beta)$. Escribir un intervalo de confianza para $\beta \in (0, \infty)$, si se quiere un nivel de confianza $1-\alpha$. En particular, escribir el intervalo para $\alpha=0,1$ si se obtiene una muestra de 4 elementos: 1,32 ; 1,13 ; 0,67 ; 0,27. Ind: use como función pivote $T(\bar{X}, \beta) = \max\{X_1, \dots, X_n\} / \beta$.

sd Se necesita un intervalo (a, b) tal que $P(a \leq \beta \leq b) = 1-\alpha$. Para ello usamos la función pivote T (cuya distribución no depende del parámetro β). Calculamos la distribución de T (Def: $Y = \max\{X_1, \dots, X_n\}$).

$$P(T \leq t) = P\left(\frac{Y}{\beta} \leq t\right) \stackrel{(*)}{=} P(Y \leq t\beta) = P(\max\{X_1, \dots, X_n\} \leq t\beta)$$

$$= P(\max\{X_1, \dots, X_n\} \leq t\beta)$$

$$\Rightarrow P(X_1 \leq t\beta, \dots, X_n \leq t\beta) = P(X_1 \leq t\beta) \cdot \dots \cdot P(X_n \leq t\beta)$$

$$\Rightarrow P(X_i \leq t\beta)^n = \left(\frac{t\beta}{\beta}\right)^n = t^n$$

Entonces, usando la función pivote, buscamos (\tilde{a}, \tilde{b}) tal que podamos luego encontrar β .

$$P(\tilde{a} \leq T \leq \tilde{b}) = 1-\alpha$$

$$\Rightarrow \begin{cases} P(T < \tilde{a}) = \alpha/2 \\ P(T > \tilde{b}) = \alpha/2 \end{cases} \text{ así los elegimos! (podría elegirse } \tilde{b}=1 \text{)}$$

$$\tilde{a} \text{ tal que } P(T \leq \tilde{a}) = \alpha$$

$$\text{Entonces, } P(T < \tilde{a}) = \tilde{a}^n = \alpha/2 \Rightarrow \tilde{a} = \sqrt[n]{\alpha/2}$$

$$P(T > \tilde{b}) = 1 - P(T \leq \tilde{b}) = 1 - \tilde{b}^n = \alpha/2 \Rightarrow \tilde{b} = \sqrt[n]{1 - \alpha/2}$$

Ahora, encontramos a β ; usamos la definición de $T = Y/\beta$

$$\begin{cases} \tilde{a} \leq T \Leftrightarrow \tilde{a}\beta \leq Y \Leftrightarrow \beta \leq Y/\tilde{a} \\ T \leq \tilde{b} \Leftrightarrow Y \leq \tilde{b}\beta \Leftrightarrow Y/\tilde{b} \leq \beta \end{cases} \Rightarrow \text{con Prob } 1-\alpha, \frac{Y}{\tilde{b}} \leq \beta \leq \frac{Y}{\tilde{a}}$$

Estancias, el intervalo (a, b) pedido será $a = \frac{Y}{5}$, $b = \frac{2Y}{5}$

En el caso contrario de esta prueba, $Y = \max\{X_1, X_2\} = 1,32$;
 $\alpha = 0,1$, $n = 4$. Estancias; FDO: F11, SE11: rechazado

$$\tilde{\alpha} = \sqrt[4]{0,05} = 0,47$$

$$\tilde{\beta} = \sqrt[4]{1-0,05} = 0,98$$

$$(1 - \tilde{\alpha}) \Rightarrow a = 1,34, \quad b = 2,78$$

Problema 3 Sean $X = (X_1, \dots, X_n)$, $Y = (Y_1, \dots, Y_m)$ muestras aleatorias mutuamente independientes provenientes de las distribuciones $N(\mu_1, \sigma^2)$, $N(\mu_2, \sigma^2)$ respect., donde σ^2 es desconocida.

a) Propone un test para contrastar $H_0: \mu_1 \geq \mu_2$ vs $H_1: \mu_1 < \mu_2$

b) ¿cuál es su decisión con un error de tipo I del 5%? Considerando los datos $n=50$, $m=60$, $\bar{X}_n = 3,2$, $\bar{Y}_m = 3,7$, $\frac{1}{n} \sum (X_i - \bar{X}_n)^2 = 0,62$, $\frac{1}{m} \sum (Y_i - \bar{Y}_m)^2 = 0,78$.

c) ¿Cómo cambia la región crítica cuando n y m decrecen?

sol Notar que las hipótesis se pueden escribir como $H_0: \mu_1 - \mu_2 \geq 0$; $H_1: \mu_1 - \mu_2 < 0$.

Obs: $\bar{X}_n \sim N(\mu_1, \sigma_n^2)$, $\bar{Y}_m \sim N(\mu_2, \sigma_m^2)$

Definiendo $W = \bar{X}_n - \bar{Y}_m$, $W \sim N(\mu_1 - \mu_2, \sigma_n^2 + \sigma_m^2)$

Si $\bar{X}_n - \bar{Y}_m$ es < 0 como \bar{X}_n estima a μ_1 e \bar{Y}_m estima a μ_2 , debería rechazarse H_0 (esta es la idea de la construcción del test).
 Por ello, la observación 2).

Como desconocemos σ , hay que usar la t-student

$$Z = \frac{\bar{X}_n - \bar{Y}_m - (\mu_1 - \mu_2)}{\sqrt{\sigma_x^2/n + \sigma_y^2/m}} \sim N(0,1)$$

$$\left\{ \begin{aligned} S_x^2 &= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2 \\ S_y^2 &= \frac{1}{m} \sum_{j=1}^m (y_j - \bar{y}_m)^2 \end{aligned} \right\}$$

y $S^2 = \frac{n S_x^2 + m S_y^2}{n+m}$ es estimador de σ^2

$$\Rightarrow Q = \frac{(n+m) S^2}{\sigma^2} \sim \chi^2_{n+m-2}$$

Entonces $\frac{Z}{\sqrt{Q/(n+m-2)}} \sim t_{n+m-2}$


$$T = \frac{Z}{\sqrt{Q/(n+m-2)}} = \frac{\bar{X}_n - \bar{Y}_m - (\mu_1 - \mu_2)}{\sigma \sqrt{\frac{1}{n} + \frac{1}{m}}} \cdot \frac{\sqrt{n+m-2}}{\sqrt{n S_x^2 + m S_y^2} / \sigma}$$

$$= \frac{[\bar{X}_n - \bar{Y}_m - (\mu_1 - \mu_2)] \sqrt{n+m-2}}{\sqrt{n S_x^2 + m S_y^2} \sqrt{\frac{1}{n} + \frac{1}{m}}} \sim t_{n+m-2}$$

Ahora, dos observaciones:

1) Consideramos el caso extremo para la hipótesis nula $\mu_1 - \mu_2 = 0$ ¿Porque?

Al considerar la familia de distribuciones normales de media $\mu_1 - \mu_2 \geq 0$, la región de rechazo debería estar "hacia el otro lado". Entonces (viendo el dibujo), se tiene que la distribución con $\mu_1 - \mu_2 = 0$ asigna más probabilidad a R (región de rechazo), que es justamente lo que se busca: poner una cota (máxima) para el error tipo I.



2) Consideramos una región de la forma $R = \{(x, y) \in \mathbb{R}^{n \times m} / \bar{X}_n - \bar{Y}_m \leq k\}$

Ahora, $P(R / H_0^*) = \alpha$, con $H_0^* : \mu_1 - \mu_2 = 0$

$$\text{Entonces, } P(\bar{X}_n - \bar{Y}_m \leq k) = P\left(T \leq \frac{k \sqrt{n+m-2}}{\sqrt{nS_x^2 + mS_y^2} \sqrt{\frac{1}{n} + \frac{1}{m}}}\right) = \alpha$$

con $T \sim t_{n+m-2}$.

En el ejemplo, $T \sim t_{108}$. Así, $k \approx -1,645$

$$k = \tilde{k} \cdot \frac{\sqrt{nS_x^2 + mS_y^2}}{\sqrt{n+m-2}} \sqrt{\frac{1}{n} + \frac{1}{m}} = -1,645 \cdot \frac{\sqrt{50 \cdot 0,62 + 60 \cdot 0,79}}{\sqrt{108}} \cdot \sqrt{\frac{1}{50} + \frac{1}{60}}$$

$$= -0,268$$

Entonces, $\bar{X}_n - \bar{Y}_m = -0,5 < -0,268$, por lo que se rechaza H_0 .



Problema 4 Sea $X = (X_1, \dots, X_n)$ mas. proveniente de la distribución Beta de parámetros $(\theta, 1)$, con función de densidad de probabilidad dada por $f(x|\theta) = \theta x^{\theta-1}$; $x \in (0, 1)$, donde $\theta > 0$.

(a) Muestre que el test mas potente de tamaño α para contrastar $H_0: \theta = \theta_0$ vs $\theta = \theta_1$, con $\theta_1 > \theta_0$ rechaza H_0 para valores grandes del estadístico $T(X) = T = \sum_{i=1}^n \ln X_i$, i.e. tiene una región crítica de la forma $R^* = \{x \in (0, 1)^n : T(x) \geq k_\alpha\}$

(b) Dem. que $-2\theta \ln(X_i) \sim \chi^2_2$. Deduzca la dist. de $-2\theta \sum_{i=1}^n \ln X_i$ bajo H_0 .

(c) ¿Cuál es la distribución en relación a H_0 ? Considerando $\theta_0 = 2$, $\theta_1 = 4\theta_0$, $\alpha = 0,05$, $n = 10$, $\sum \ln x_i = -5,846$ y un error de tipo I de 5%. ¿Cuál es el error de tipo II? ¿El p-valor del test es mayor o menor que 5%?

sol a) Naturalmente, Neyman-Pearson.

$$r = \frac{f_n(x_1, \dots, x_n | \theta = \theta_1)}{f_n(x_1, \dots, x_n | \theta = \theta_0)} = \frac{\theta_1^n \left(\prod_{i=1}^n x_i\right)^{\theta_1 - 1}}{\theta_0^n \left(\prod_{i=1}^n x_i\right)^{\theta_0 - 1}} = \left(\frac{\theta_1}{\theta_0}\right)^n \left(\prod_{i=1}^n x_i\right)^{\theta_1 - \theta_0} \geq k$$

Aplicando \ln , $= n \ln(\theta_1/\theta_0) + (\theta_1 - \theta_0) \ln\left(\prod_{i=1}^n x_i\right) \geq \ln(k)$ $\theta_1 - \theta_0 > 0$

$$\ln\left(\prod_{i=1}^n x_i\right) = \sum_{i=1}^n \ln x_i \geq \frac{\ln(k) - n \ln(\theta_1/\theta_0)}{\theta_1 - \theta_0} = k'_\alpha$$

Esto define R^*

b) según JTCV, si $r: (0, 1) \rightarrow \mathbb{R}_+$, entonces $s: \mathbb{R}_+ \rightarrow (0, 1)$
 $x \rightarrow r(x) = -2\theta \ln(x)$ $y \rightarrow s(y) = e^{-y/2\theta}$
 es la muestra de r , y $\frac{\partial s(y)}{\partial y} = e^{-y/2\theta} \cdot \frac{-1}{2\theta} \Rightarrow \left| \frac{\partial s(y)}{\partial y} \right| = \frac{e^{-y/2\theta}}{2\theta}$

$$\text{Entonces, } f_y(y) = f_x(r(y)) \left| \frac{\partial s(y)}{\partial y} \right| = \theta \left(e^{-y/2\theta} \right)^{\theta-1} \frac{e^{-y/2\theta}}{2\theta} = \frac{e^{-\frac{y}{2\theta} \theta} e^{\frac{y}{2\theta}} e^{-y/2\theta}}{2} = \frac{1}{2} e^{-y/2}$$

La densidad de una χ^2_n es

$$f_n(y) = \frac{y^{n/2-1} e^{-y/2}}{\Gamma(n/2) 2^{n/2}}$$

si $n=2$, se tiene $f_2(y) = \frac{y^{2/2-1} e^{-y/2}}{\Gamma(2/2) 2^{2/2}} = \frac{e^{-y/2}}{2}$

Como los (X_i) son indep. $(-2\theta \ln(X_i) = Y_i)$ son indep. Así, la suma de n χ^2_2 da χ^2_{2n} .

$$\Rightarrow -2\theta \sum_{i=1}^n \ln X_i \sim \chi^2_{2n}$$

c) Para encontrar K_α , necesitamos que $P(T \geq K_\alpha) = \alpha$, con $\sum_{i=1}^n \ln X_i = T$

Reescribiendo $-2\theta \sum_{i=1}^n \ln X_i = -2\theta T \sim \chi^2_{2n}$

Y en \mathbb{R}^* , $T \geq K_\alpha \Leftrightarrow -2\theta T \leq -2\theta K_\alpha = \tilde{K}$

Entonces, $P(T \geq K_\alpha | H_0) = P(\chi^2_{2n} \leq \tilde{K} | H_0) = \alpha$

si $\alpha = 0,05$, $n = 10$, $\sum_{i=1}^n \ln X_i = -5,846$, $\theta_0 = 2$, $\theta_1 = 2,8$

$P(\chi^2_{20} \leq \tilde{K}) = 0,05 \Leftrightarrow \tilde{K} = 10,85 \Rightarrow K_\alpha = -\frac{\tilde{K}}{2\theta} = -2,71$

Así, como $\sum_{i=1}^n \ln X_i = -5,846 \leq K_\alpha$, no se rechaza H_0 .