

Inferencia Estadística Examen III

FACULTAD
DE
CIENCIAS
UNIVERSIDAD DE GRANADA



Los Del DGIIM, losdeldgiim.github.io

Doble Grado en Ingeniería Informática y Matemáticas
Universidad de Granada



Esta obra está bajo una Licencia Creative Commons Atribución-NoComercial-SinDerivadas 4.0 Internacional (CC BY-NC-ND 4.0).

Eres libre de compartir y redistribuir el contenido de esta obra en cualquier medio o formato, siempre y cuando des el crédito adecuado a los autores originales y no persigas fines comerciales.

Inferencia Estadística Examen III

Los Del DGIIM, losdeldgiim.github.io

José Manuel Sánchez Varbas

Granada, 2026

Asignatura Inferencia Estadística.

Curso Académico 2023-24.

Grado Grado en Matemáticas y Grado en Ingeniería Informática y Matemáticas.

Descripción Examen Ordinario.

Fecha 23 de Enero de 2024.

Ejercicio 1. Sean (X_1, \dots, X_{n_1}) y (Y_1, \dots, Y_{n_2}) m.a.s. de X e Y , variables que sigan $N(\mu_1, 4)$ y $N(\mu_2, 5)$ respectivamente.

- a) Si $\mu_1 = 2$, $\mu_2 = 3$ y sean (X_1, \dots, X_8) y (Y_1, \dots, Y_{10}) dos muestras de tamaño 8 y 10 respectivamente con medias muestrales \bar{X} , \bar{Y} , calcular el percentil 99 de

$$V = \frac{\bar{X} - \bar{Y} + 1}{\sqrt{\frac{\sum_{i=1}^8 (X_i - \bar{X})^2}{4} + \frac{\sum_{i=1}^{10} (Y_i - \bar{Y})^2}{5}}}. \quad (1)$$

- b) Calcular el intervalo de confianza para $\mu_1 - \mu_2$ de menor longitud esperada uniformemente a nivel de confianza $1 - \alpha$. ¿Cómo sería el intervalo si las varianzas fueran desconocidas pero iguales?

Ejercicio 2.

- a) Sea X una v.a. con función de densidad

$$f_{\theta}(x) = \frac{\theta}{2} x^{-3/2}, \quad x > \theta^2. \quad (2)$$

Calcular el UMVUE y determinar para qué valores de n existe. ¿Es eficiente?

- b) Sea

$$f_{\theta}(x) = \theta T(x) e^{-\theta x}, \quad x > 0, \theta > 0,$$

en una familia regular según Fréchet–Cramér–Rao.

- b1) Sabiendo que¹ $I_{X_1, \dots, X_n}(\theta) = \frac{n}{\theta^2}$, calcular $E[X]$ y $\text{Var}[X]$.

- b2) Sabiendo que

$$\sum_{i=1}^n \frac{T(X_i)}{n}$$

es un estimador eficiente de $2/\theta$, calcular $T(x)$.

Ejercicio 3.

- a) Enunciar y demostrar el Teorema de Zehna definiendo previamente los siguientes conceptos: función de verosimilitud de un parámetro, función de verosimilitud de una función paramétrica y estimador máximo verosímil para funciones paramétricas.

- b) Calcular la función de verosimilitud de

$$\lambda = (\theta - 1)^2$$

asociada a una realización muestral cuyo máximo valor es 3 si

$$f_{\theta}(x) = e^{x-\theta}, \quad x \leq \theta, \theta > 0.$$

¹Originalmente era $I_{X_1, \dots, X_n}(\theta) = \frac{2n}{\theta^2}$, pero este dato era incompatible con el ejercicio. Se ha optado por eliminar el 2 para que todo salga como se espera.

Ejercicio 4. Sea (X_1, \dots, X_n) una m.a.s. de X v.a. con función de densidad

$$f_{\theta}(x) = \frac{1}{\sqrt{8\theta}\sqrt{x-1}}, \quad 1 < x < 2\theta + 1. \quad (3)$$

Deducir el test más potente de tamaño arbitrario para contrastar

$$H_0 : \theta = \theta_0 \quad \text{frente a} \quad H_1 : \theta = \theta_1$$

siendo $\theta_1 < \theta_0$. Calcular la potencia.

Ejercicio 5.

- a) Test de Kolmogorov–Smirnov.
 - i) Plantear el problema de contraste.
 - ii) Dar el valor del estadístico.
 - iii) Enunciar el teorema que justifica su uso.
 - iv) Ventajas frente al test χ^2 .
- b) Se cuentan el número de tutorías a lo largo de un curso por 50 profesores. Se quiere contrastar si el número de tutorías por profesor se puede describir mediante una distribución de Poisson.

Número de tutorías	0	1	2	3	4	5
Número de profesores	2	5	10	14	12	7

Ejercicio 1. Sean (X_1, \dots, X_{n_1}) y (Y_1, \dots, Y_{n_2}) m.a.s. de X e Y , variables que siguen $N(\mu_1, 4)$ y $N(\mu_2, 5)$ respectivamente.

- a) Si $\mu_1 = 2$, $\mu_2 = 3$ y sean (X_1, \dots, X_8) y (Y_1, \dots, Y_{10}) dos muestras de tamaño 8 y 10 respectivamente con medias muestrales \bar{X} , \bar{Y} , calcular el percentil 99 de

$$V = \frac{\bar{X} - \bar{Y} + 1}{\sqrt{\frac{\sum_{i=1}^8 (X_i - \bar{X})^2}{4} + \frac{\sum_{i=1}^{10} (Y_i - \bar{Y})^2}{5}}}. \quad (1)$$

Del enunciado del problema sacamos que

$$X_i \rightsquigarrow N(\mu_1, 4), \quad i = 1, \dots, n_1$$

$$Y_j \rightsquigarrow N(\mu_2, 5) \quad j = 1, \dots, n_2$$

y en este apartado, $n_1 = 8$ y $n_2 = 10$. Buscamos obtener la distribución de V . Para ello, primero hallamos la distribución del numerador.

Como $\mu_1 = 2$ y $\mu_2 = 3$, entonces

$$E[\bar{X} - \bar{Y} + 1] = E[\bar{X}] - E[\bar{Y}] + 1 = \mu_1 - \mu_2 + 1 = 2 - 3 + 1 = 0$$

Por teoría sabemos que

$$X \rightsquigarrow N(\mu_1, 4) \implies \bar{X} \rightsquigarrow N\left(\mu_1, \frac{4}{n_1}\right)$$

$$Y \rightsquigarrow N(\mu_2, 5) \implies \bar{Y} \rightsquigarrow N\left(\mu_2, \frac{5}{n_2}\right)$$

Así, asumiendo que (X_1, \dots, X_{n_1}) y (Y_1, \dots, Y_{n_2}) son independientes, entonces

$$\bar{X} - \bar{Y} \rightsquigarrow N\left(\mu_1 - \mu_2, \frac{4}{n_1} + \frac{5}{n_2}\right)$$

y se obtiene que

$$\text{Var}(\bar{X} - \bar{Y} + 1) = \text{Var}(\bar{X} - \bar{Y}) = \frac{4}{n_1} + \frac{5}{n_2} = \frac{4}{8} + \frac{5}{10} = \frac{1}{2} + \frac{1}{2} = 1$$

Deducimos entonces que $Z = \bar{X} - \bar{Y} + 1 \rightsquigarrow N(0, 1)$

Falta hallar la distribución del denominador. Usaremos que

$$\frac{(n_1 - 1)S_1^2}{\sigma_1^2} = \frac{\sum_{i=1}^{n_1} (X_i - \bar{X})^2}{\sigma_1^2} \rightsquigarrow \chi^2(n_1 - 1)$$

$$\frac{(n_2 - 1)S_2^2}{\sigma_2^2} = \frac{\sum_{j=1}^{n_2} (Y_j - \bar{Y})^2}{\sigma_2^2} \rightsquigarrow \chi^2(n_2 - 1)$$

y como estas últimas v.a. son independientes, por serlo las m.a.s. de X e Y , podemos aplicar la reproductividad de la distribución χ^2 :

$$W = \frac{\sum_{i=1}^{n_1} (X_i - \bar{X})^2}{\sigma_1^2} + \frac{\sum_{j=1}^{n_2} (Y_j - \bar{Y})^2}{\sigma_2^2} \rightsquigarrow \chi^2(n_1 - 1 + n_2 - 1) = \chi^2(n_1 + n_2 - 2) = \chi^2(16)$$

En estas condiciones puede aplicarse la construcción de la distribución T de Student

$$T = \frac{Z}{\sqrt{W/16}} \rightsquigarrow t(16)$$

y basta notar que

$$V = \frac{Z}{\sqrt{W}} = \frac{Z}{\sqrt{16 \cdot W/16}} = \frac{Z}{\sqrt{16} \sqrt{W/16}} = \frac{1}{4} \frac{Z}{\sqrt{W/16}} = \frac{1}{4} T$$

La tabla proporcionada para la T de Student cumple que

$$P(T \leq q_p) = p \iff P(T_n > t_{n,1-p}) = 1 - p$$

donde q_p es el percentil $p \in]0, 1[$, $t_{n,1-p}$ es el valor tabulado para la fila n y la columna $1 - p$, y $T_n \stackrel{not}{=} T \rightsquigarrow t(n)$. El percentil 99 de V será consecuentemente

$$q_{0,99}(V) = \frac{1}{4} t_{16;0,01} \approx \frac{1}{4} \cdot 2,5835 \approx 0,645875$$

- b) Calcular el intervalo de confianza para $\mu_1 - \mu_2$ de menor longitud esperada uniformemente a nivel de confianza $1 - \alpha$. ¿Cómo sería el intervalo si las varianzas fueran desconocidas pero iguales?

Ya sabemos que

$$\bar{X} - \bar{Y} \rightsquigarrow N\left(\mu_1 - \mu_2, \frac{4}{n_1} + \frac{5}{n_2}\right)$$

Y como nos piden el intervalo de confianza (se asume que bilateral), entonces por el método del pivote visto en teoría, usando como pivote

$$T(X_1, \dots, X_{n_1}, Y_1, \dots, Y_{n_2}; \mu_1 - \mu_2) = \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\frac{4}{n_1} + \frac{5}{n_2}}} \rightsquigarrow N(0, 1)$$

este debe verificar, por definición de intervalo de confianza, lo siguiente

$$P_{\mu_1, \mu_2} \left(\lambda_1 < \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\frac{4}{n_1} + \frac{5}{n_2}}} < \lambda_2 \right) \geq 1 - \alpha \quad \forall (\mu_1, \mu_2) \in \mathbb{R}^2$$

para ciertos $\lambda_1, \lambda_2 \in \mathbb{R}$. Buscamos aislar la diferencia de medias poblacionales en el centro de la cadena de desigualdades, luego

$$\begin{aligned}\lambda_1 &< \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\frac{4}{n_1} + \frac{5}{n_2}}} < \lambda_2 \\ \iff \lambda_1 \sqrt{\frac{4}{n_1} + \frac{5}{n_2}} &< (\bar{X} - \bar{Y}) - (\mu_1 - \mu_2) < \lambda_2 \sqrt{\frac{4}{n_1} + \frac{5}{n_2}} \\ \iff \bar{Y} - \bar{X} + \lambda_1 \sqrt{\frac{4}{n_1} + \frac{5}{n_2}} &< -(\mu_1 - \mu_2) < \bar{Y} - \bar{X} + \lambda_2 \sqrt{\frac{4}{n_1} + \frac{5}{n_2}} \\ \iff \bar{X} - \bar{Y} - \lambda_2 \sqrt{\frac{4}{n_1} + \frac{5}{n_2}} &< \mu_1 - \mu_2 < \bar{X} - \bar{Y} - \lambda_1 \sqrt{\frac{4}{n_1} + \frac{5}{n_2}}\end{aligned}$$

La solución para obtener el intervalo de confianza de menor longitud esperada uniformemente a nivel de confianza $1 - \alpha$ se alcanza con $\lambda_1 = -z_{\alpha/2}$, $\lambda_2 = z_{\alpha/2}$, donde $P[Z > z_\alpha] > \alpha$, y el intervalo de confianza bilateral es

$$\left(\bar{X} - \bar{Y} - z_{\alpha/2} \sqrt{\frac{4}{n_1} + \frac{5}{n_2}}, \bar{X} - \bar{Y} + z_{\alpha/2} \sqrt{\frac{4}{n_1} + \frac{5}{n_2}} \right)$$

Si se pidiera cualquiera de los dos unilaterales, entonces

- Si $\lambda_1 = -\infty$, se sustituye el extremo superior del intervalo bilateral anterior por $+\infty$, y $z_{\alpha/2}$ por z_α .
- Si $\lambda_2 = +\infty$, se sustituye el extremo inferior del intervalo bilateral anterior por $-\infty$, y $z_{\alpha/2}$ por z_α .

Si las varianzas fueran desconocidas pero iguales, entonces el pivote sería

$$T(X_1, \dots, X_{n_1}, Y_1, \dots, Y_{n_2}; \mu_1 - \mu_2) = \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{S_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \rightsquigarrow t(n_1 + n_2 - 2)$$

donde

$$S_p^2 = \frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2}$$

y como la T de Student tiene las mismas propiedades de simetría respecto al origen que $N(0, 1)$, entonces el intervalo de confianza bilateral a nivel de confianza $1 - \alpha$ sería

$$\left(\bar{X} - \bar{Y} - t_{n_1+n_2-2; \alpha/2} S_p \sqrt{\frac{4}{n_1} + \frac{5}{n_2}}, \bar{X} - \bar{Y} + t_{n_1+n_2-2; \alpha/2} S_p \sqrt{\frac{4}{n_1} + \frac{5}{n_2}} \right)$$

donde $P[T_{n_1+n_2-2} > t_{n_1+n_2-2; \alpha}] = \alpha$ y nuevamente si se pidiera cualquiera de los dos unilaterales, entonces

- Si $\lambda_1 = -\infty$, se sustituye el extremo superior del intervalo bilateral anterior por $+\infty$, y $t_{n_1+n_2-2; \alpha/2}$ por $t_{n_1+n_2-2; \alpha}$.
- Si $\lambda_2 = +\infty$, se sustituye el extremo inferior del intervalo bilateral anterior por $-\infty$, y $t_{n_1+n_2-2; \alpha/2}$ por $t_{n_1+n_2-2; \alpha}$.

Ejercicio 2.

a) Sea X una v.a. con función de densidad

$$f_{\theta}(x) = \frac{\theta}{2}x^{-3/2}, \quad x > \theta^2. \quad (2)$$

Calcular el UMVUE y determinar para qué valores de n existe. ¿Es eficiente?

Buscamos obtener el UMVUE mediante el método alternativo visto en teoría. Para ello, en primer lugar hay que encontrar un estadístico suficiente y completo T , y luego una función del estadístico $h(T)$ (denotaremos indistintamente $T \stackrel{not}{=} T(X_1, \dots, X_n)$, para una m.a.s. (X_1, \dots, X_n) con $n \in \mathbb{N}$ fijo) insesgada en $g(\theta) = \theta$ (como no se especifica de quién es el UMVUE, se asume que del parámetro), estimadora y con momento de segundo orden finito. Entonces $h(T)$ será el UMVUE.

El estadístico suficiente se calcula por medio del Teorema de Factorización de Neyman-Fisher. La función conjunta es la siguiente

$$f_{\theta}^n(x_1, \dots, x_n) \stackrel{indep.}{=} \prod_{i=1}^n f_{\theta}(x_i)$$

Suponemos en este punto que $\theta > 0$ (de lo contrario, $f_{\theta}(x_i) = 0 \quad \forall i = 1, \dots, n$), y vemos que

$$x_i > \theta^2 \quad \forall i = 1, \dots, n \iff I_{\mathbb{R}^+}(x_i - \theta^2) = 1 \quad \forall i = 1, \dots, n \iff I_{\mathbb{R}^+}(x_{(1)} - \theta^2) = 1$$

de donde se deduce que

$$f_{\theta}^n(x_1, \dots, x_n) = \prod_{i=1}^n \frac{\theta}{2} x_i^{-3/2} I_{\mathbb{R}^+}(x_{(1)} - \theta^2) = \left(\frac{\theta}{2}\right)^n \prod_{i=1}^n x_i^{-3/2} I_{\mathbb{R}^+}(x_{(1)} - \theta^2)$$

Tomando $T(X_1, \dots, X_n) = X_{(1)}$ y

$$h(x_1, \dots, x_n) = \prod_{i=1}^n x_i^{-3/2}, \quad g_{\theta}(t) = \left(\frac{\theta}{2}\right)^n I_{\mathbb{R}^+}(t - \theta^2)$$

Se cumple que

$$f_{\theta}^n(x_1, \dots, x_n) = h(x_1, \dots, x_n) g_{\theta}(T(x_1, \dots, x_n)) \quad \forall (x_1, \dots, x_n) \in \mathcal{X}^n$$

donde h es independiente del parámetro θ y g_{θ} depende de la muestra solo a través del estadístico, luego, por el Teorema de Factorización de Neyman-Fisher, el estadístico T es suficiente.

Ahora, hay que comprobar que este estadístico es completo, lo cual se hará por definición. Sabemos por teoría que la distribución del mínimo es

$$F_T(t) = 1 - (1 - F_X(t))^n \implies f_T(t) = n(1 - F_X(t))^{n-1} f_\theta(t)$$

Hallamos ahora la función de distribución de X :

$$\begin{aligned} F_X(t) &= \int_{\theta^2}^t f_\theta(x) dx = \int_{\theta^2}^t \frac{\theta}{2} x^{-3/2} dx = \frac{\theta}{2} \int_{\theta^2}^t x^{-3/2} dx = \frac{\theta}{2} \cdot \left[\frac{x^{-1/2}}{-1/2} \right]_{\theta^2}^t = \\ &= \frac{\theta}{2} \cdot (-2(t^{-1/2} - (\theta^2)^{-1/2})) = -\theta \left(\frac{1}{\sqrt{t}} - \frac{1}{\theta} \right) = -\theta \frac{\theta - \sqrt{t}}{\theta \sqrt{t}} = \\ &= \frac{\sqrt{t} - \theta}{\sqrt{t}} = 1 - \frac{\theta}{\sqrt{t}} \quad t > \theta^2 \end{aligned}$$

La función de densidad del estadístico será entonces

$$\begin{aligned} f_T(t) &= n(1 - F_X(t))^{n-1} f_\theta(t) = n \left(\frac{\theta}{\sqrt{t}} \right)^{n-1} \frac{\theta}{2} t^{-3/2} = \\ &= \frac{n\theta^n}{2} \frac{t^{-3/2}}{t^{(n-1)/2}} = \frac{n\theta^n}{2} t^{-(n/2+1)} \quad t > \theta^2 \end{aligned}$$

Sea h una función medible verificando

$$\begin{aligned} 0 = E[h(T)] &\stackrel{def}{=} \int_{\theta^2}^{+\infty} h(t) f_T(t) dt = \int_{\theta^2}^{+\infty} h(t) \frac{n\theta^n}{2} t^{-(n/2+1)} dt = \\ &= \frac{n\theta^n}{2} \int_{\theta^2}^{+\infty} h(t) t^{-(n/2+1)} dt \end{aligned}$$

como $\frac{n\theta^n}{2} \neq 0 \quad \forall n \in \mathbb{N}, \quad \forall \theta > 0$, debe ser

$$\int_{\theta^2}^{+\infty} h(t) t^{-(n/2+1)} dt = 0$$

Por el Teorema Fundamental del Cálculo, podemos considerar una primitiva $H(t)$ del integrando $h(t)t^{-(n/2+1)}$, y esta cumple, por la Regla de Barrow, que $\lim_{m \rightarrow +\infty} H(m) - H(\theta^2) = 0 \quad \forall \theta > 0$. Derivando respecto de θ , se obtiene que

$$-\frac{d}{d\theta} H(\theta^2) = 0 \iff -h(\theta^2)(\theta^2)^{-(n/2+1)}(2\theta) = 0 \iff -2\theta^{-(n+1)}h(\theta^2) = 0 \stackrel{(*)}{\iff} h(\theta^2) = 0$$

donde en $(*)$ se ha usado que $-2\theta^{-(n+1)} \neq 0$ por ser $\theta > 0$, $n \in \mathbb{N}$ y $-2 \neq 0$. Equivalentemente,

$$\forall \theta \in \Theta =]0, +\infty[\quad h(\theta^2) = 0 \iff h(t) = 0 \quad \forall t > 0$$

(tomando $t = \theta^2 \in]0, +\infty[$). Por tanto

$$]0, +\infty[\subseteq \{t : h(t) = 0\}$$

y consecuentemente

$$1 \geq P[h(T) = 0] \geq P[T > 0] = 1 \implies P[h(T) = 0] = 1$$

y entonces por definición concluimos que T es un estadístico completo. Tenemos entonces en este punto que T es un estadístico suficiente y completo.

Ahora hay que buscar un estimador insesgado en $g(\theta)$ y de segundo orden finito. Sea h (independiente de la anterior) función medible tal que

$$\theta = g(\theta) = E[h(T)] = \frac{n\theta^n}{2} \int_{\theta^2}^{+\infty} h(t)t^{-(n/2+1)} dt \iff$$

$$\int_{\theta^2}^{+\infty} h(t)t^{-(n/2+1)} dt = \frac{2\theta}{n\theta^n} = \frac{2}{n\theta^{n-1}} = \frac{2}{n}\theta^{1-n}$$

Derivamos respecto de θ a ambos lados e igualamos. El miembro izquierdo ya lo tenemos por el apartado anterior:

$$-2\theta^{-(n+1)}h(\theta^2)$$

y el derecho es

$$\frac{2}{n}(1-n)\theta^{1-n-1} = \frac{2(1-n)}{n}\theta^{-n}$$

Despejamos $h(\theta^2)$:

$$-2\theta^{-(n+1)}h(\theta^2) = \frac{2(1-n)}{n}\theta^{-n} \iff$$

$$h(\theta^2) = \frac{2(1-n)}{-2\theta^{-(n+1)}}\theta^{-n} = \frac{n-1}{n} \frac{\theta^{-n}}{\theta^{-(n+1)}} = \frac{n-1}{n}\theta$$

de donde

$$h(t) = \frac{n-1}{n}\sqrt{t}$$

Por construcción $h(T)$ es insesgada en $g(\theta)$. Vemos que $h(T)$ también es estimador de $g(\theta)$, pues $\Theta =]0, +\infty[$, y $g(\theta) = \theta \implies g(\Theta) =]0, +\infty[$. Como $T = X_{(1)} > \theta^2 > 0$ y $\frac{n-1}{n} > 0$ si $n \geq 2$, luego $h(T) > 0$ si $n \geq 2$. Queda comprobar que tiene momento de segundo orden finito.

Ello se cumplirá en caso de que $E[h(T)^2] < +\infty$:

$$E[h(T)^2] \stackrel{def}{=} \int_{\theta^2}^{+\infty} h(t)^2 f_T(t) dt = \int_{\theta^2}^{+\infty} \left(\frac{n-1}{n}\right)^2 t \frac{n\theta^n}{2} t^{-(n/2+1)} dt =$$

$$\frac{\theta^n(n-1)^2}{2n} \int_{\theta^2}^{+\infty} t^{-n/2} dt = \frac{\theta^n(n-1)^2}{2n} [t^{-n/2+1}]_{\theta^2}^{+\infty} =$$

$$\frac{\theta^n(n-1)^2}{2n} \left(\lim_{m \rightarrow +\infty} m^{-n/2+1} - \theta^{-n/2+1} \right)$$

Y vemos que

$$E[h(T)^2] < +\infty \iff \lim_{m \rightarrow +\infty} m^{-n/2+1} < +\infty \iff -\frac{n}{2} + 1 < 0 \iff$$

$$-\frac{n}{2} < -1 \iff -n < -2 \iff n > 2 \iff n \geq 3$$

ya que si $n < 3$, es decir $n \in \{1, 2\}$:

a) Si $n = 1$

$$\lim_{m \rightarrow +\infty} m^{-n/2+1} = \lim_{m \rightarrow +\infty} m^{-1/2+1} = \lim_{m \rightarrow +\infty} \sqrt{m} = +\infty$$

b) Si $n = 2$

$$\int_{\theta^2}^{+\infty} t^{-n/2} dt = \int_{\theta^2}^{+\infty} t^{-1} dt = \int_{\theta^2}^{+\infty} \frac{1}{t} dt = \ln[t]_{\theta^2}^{+\infty}$$

y en ambos casos el momento de segundo orden no sería finito (aparte de no ser $h(T)$ estimador si $n = 1$ por lo estudiado antes). Por tanto, por el Teorema de Lehmann-Scheffé, $E[h(T)/T] = h(T)$ es el UMVUE para $g(\theta)$, y existe siempre y cuando $n > 2 \iff n \geq 3$.

Respecto a la eficiencia, sabemos por un corolario visto en teoría que solo existen estimadores eficientes para familias de tipo exponencial (además de regulares en el sentido de Fréchet–Cramér–Rao), pero esta familia no puede serlo, ya que $\mathcal{X} =]-\theta^2, +\infty[$, es decir, el conjunto de valores de la variable depende de θ , luego ya no tendríamos que la familia es de tipo exponencial. Consecuentemente, el UMVUE obtenido no verifica la definición de estimador eficiente, definido a su vez sobre familias regulares, por lo que no es eficiente.

b) Sea

$$f_{\theta}(x) = \theta T(x) e^{-\theta x}, \quad x > 0, \theta > 0,$$

en una familia regular según Fréchet–Cramér–Rao.

b1) Sabiendo que² $I_{X_1, \dots, X_n}(\theta) = \frac{n}{\theta^2}$, calcular $E[X]$ y $\text{Var}[X]$.

Por ser regular según FCR, sabemos que se verifica que

$$E_{\theta} \left[\frac{\partial \ln f_{\theta}(x)}{\partial \theta} \right] = 0$$

Así

$$\ln f_{\theta}(x) = \ln \theta + \ln(T(x)) - \theta x \implies \frac{\partial \ln f_{\theta}(x)}{\partial \theta} = \frac{1}{\theta} - x$$

La esperanza de X puede obtenerse ya

$$E_{\theta} \left[\frac{1}{\theta} - X \right] = E_{\theta} \left[\frac{\partial \ln f_{\theta}(x)}{\partial \theta} \right] = 0 \iff E_{\theta} \left[\frac{1}{\theta} \right] - E[X] = 0 \iff E[X] = \frac{1}{\theta}$$

Como

$$\text{Var}_{\theta} \left[\frac{\partial \ln f_{\theta}(x)}{\partial \theta} \right] = I_X(\theta)$$

²Originalmente era $I_{X_1, \dots, X_n}(\theta) = \frac{2n}{\theta^2}$, pero este dato era incompatible con el ejercicio. Se ha optado por eliminar el 2 para que todo salga como se espera.

usando la aditividad de la función de información de Fisher respecto a la v.a. y respecto a la m.a.s. de la v.a., deducimos que

$$I_{X_1, \dots, X_n}(\theta) = nI_X(\theta) \iff \frac{n}{\theta^2} = nI_X(\theta) \iff I_X(\theta) = \frac{1}{\theta^2}$$

de donde

$$\text{Var}_\theta \left[\frac{1}{\theta} - X \right] = \text{Var}_\theta(X) = I_X(\theta) = \frac{1}{\theta^2}$$

b2) Sabiendo que

$$\sum_{i=1}^n \frac{T(X_i)}{n}$$

es un estimador eficiente de $2/\theta$, calcular $T(x)$.

Buscamos aplicar el Teorema de Caracterización de Estimadores Eficientes. Para ello, obtenemos la función conjunta de la m.a.s. de X

$$f_\theta^n(x_1, \dots, x_n) \stackrel{\text{indep}}{=} \prod_{i=1}^n f_\theta(x_i)$$

Se supondrá a partir de ahora que $x_i \in \mathbb{R}^+ \quad \forall i = 1, \dots, n$ y $\theta \in \mathbb{R}^+$. De lo contrario, $f_\theta(x_i) = 0 \quad \forall i = 1, \dots, n$.

$$f_\theta^n(x_1, \dots, x_n) \stackrel{\text{indep}}{=} \prod_{i=1}^n f_\theta(x_i) = \prod_{i=1}^n \theta T(x_i) e^{-\theta x_i} = \theta^n \prod_{i=1}^n T(x_i) e^{-\theta x_i}$$

$$\ln f_\theta^n(x_1, \dots, x_n) = n \ln \theta + \sum_{i=1}^n (\ln T(x_i) - \theta x_i)$$

$$\frac{\partial \ln f_\theta^n(X_1, \dots, X_n)}{\partial \theta} = \frac{n}{\theta} - \sum_{i=1}^n X_i = -\frac{n}{2} \cdot \left(\sum_{i=1}^n \frac{2X_i}{n} - \frac{2}{\theta} \right)$$

Sea ahora $g(\theta) = 2/\theta$. Denotamos $\bar{T} \stackrel{\text{not}}{=} \sum_{i=1}^n T(X_i)/n$. Como $g(\theta)$ es una función paramétrica derivable y estrictamente monótona ($g'(\theta) \neq 0 \quad \forall \theta \in \Theta = \mathbb{R}^+$), el enunciado nos dice que la familia es regular, y $0 < I_X(\theta) = 2/\theta^2 < +\infty \quad \forall \theta \in \Theta$, por el Teorema de Caracterización de Estimadores Eficientes, sabemos que \bar{T} es eficiente si y solo si $\forall \theta \in \Theta \quad \exists a(\theta) \neq 0$ tal que

$$P_\theta \left[\frac{\partial \ln f_\theta^n(X_1, \dots, X_n)}{\partial \theta} = a(\theta) [\bar{T}(X_1, \dots, X_n) - g(\theta)] \right] = 1$$

y

$$I_{(X_1, \dots, X_n)}(\theta) = a(\theta) g'(\theta)$$

Como

$$\frac{\partial \ln f_\theta^n(X_1, \dots, X_n)}{\partial \theta} = a(\theta) [\bar{T}(X_1, \dots, X_n) - g(\theta)] \iff$$

$$-\frac{n}{2} \cdot \left(\sum_{i=1}^n \frac{2X_i}{n} - \frac{2}{\theta} \right) = a(\theta) [\bar{T}(X_1, \dots, X_n) - g(\theta)]$$

claramente por comparación se obtiene que

$$\sum_{i=1}^n \frac{T(X_i)}{n} = \bar{T}(X_1, \dots, X_n) = \sum_{i=1}^n \frac{2X_i}{n}, \quad g(\theta) = \frac{2}{\theta}, \quad a(\theta) = -\frac{n}{2}$$

Es claro que $\bar{T}(X_1, \dots, X_n) = \sum_{i=1}^n 2X_i/n$ es un estimador, pues $\Theta = \mathbb{R}^+$, $g(\Theta) = \mathbb{R}^+$, y $T(x_1, \dots, x_n) > 0 \quad \forall (x_1, \dots, x_n) \in \mathcal{X}^n = (\mathbb{R}^+)^n$ y $n > 0 \quad \forall n \in \mathbb{N}$. Además, tanto $a(\theta)$ como $g(\theta)$ verifican todas las condiciones del teorema, pues

$$g'(\theta) = 2 \cdot (\theta^{-1})' = 2 \cdot (-\theta^{-2}) = -\frac{2}{\theta^2} < 0$$

porque $2, \theta > 0$ y $a(\theta) = -n/2 < 0 \quad \forall n \in \mathbb{N}$, en particular, $a(\theta) \neq 0 \quad \forall \theta \in \Theta \quad \forall n \in \mathbb{N}$, y usando la aditividad de la función de información de Fisher, obtenemos

$$\frac{n}{\theta^2} = I_{(X_1, \dots, X_n)}(\theta) = a(\theta)g'(\theta) = -\frac{n}{2} \left(-\frac{2}{\theta^2} \right) = \frac{n}{\theta^2}$$

Por comparación directa

$$\sum_{i=1}^n \frac{T(X_i)}{n} = \bar{T}(X_1, \dots, X_n) = \sum_{i=1}^n \frac{2X_i}{n} \iff T(X_i) = 2X_i$$

de donde $T(x) = 2x$.

Ejercicio 3.

- a) Enunciar y demostrar el Teorema de Zehna definiendo previamente los siguientes conceptos: función de verosimilitud de un parámetro, función de verosimilitud de una función paramétrica y estimador máximo verosímil para funciones paramétricas.

Definición 0.1 (Función de Verosimilitud de un Parámetro). Sea X una v.a. con distribución en una familia paramétrica de distribuciones, $\{F_\theta, \theta \in \Theta\}$. Sea $f_\theta(x)$ la f.m.p. (caso discreto) ó la f.d.d. (caso continuo) de X . Se considera X_1, \dots, X_n una m.a.s. de X y sea $f_\theta^n(x_1, \dots, x_n)$ su f.m.p. ó f.d.d. (respectivamente) conjunta con $\theta \in \Theta$. Para cada x_1, \dots, x_n realización muestral, se define la *función de verosimilitud* asociada a dichos valores de la muestra como una función de θ de la siguiente forma:

$$\begin{aligned} L_{x_1, \dots, x_n} : \Theta &\longrightarrow \mathbb{R}^+ \cup \{0\} \\ \theta &\longmapsto L_{x_1, \dots, x_n}(\theta) = f_\theta^n(x_1, \dots, x_n) \end{aligned}$$

Definición 0.2 (Función de Verosimilitud de una Función Paramétrica). Sea $g : \Theta \rightarrow \Lambda$ una función paramétrica. En el contexto de la Definición 0.1, para cada x_1, \dots, x_n realización muestral, se define la *función de verosimilitud* de $\lambda = g(\theta)$ asociada a dicha realización como:

$$\begin{aligned} M_{x_1, \dots, x_n} : \Lambda &\longrightarrow \mathbb{R}^+ \cup \{0\} \\ \lambda &\longmapsto M_{x_1, \dots, x_n}(\lambda) = \sup_{\theta \in g^{-1}(\lambda)} L_{x_1, \dots, x_n}(\theta) \end{aligned}$$

Definición 0.3 (Estimador Máximo Verosímil para Funciones Paramétricas). Un estimador $\hat{\lambda}(X_1, \dots, X_n)$ de λ es *estimador de máxima verosimilitud* (EMV) de λ si:

$$\forall (x_1, \dots, x_n) \in \mathcal{X}^n, \quad M_{x_1, \dots, x_n}(\hat{\lambda}(x_1, \dots, x_n)) = \max_{\lambda \in \Lambda} M_{x_1, \dots, x_n}(\lambda)$$

Teorema 0.1 (de Invarianza de Zehna). Sea X una v.a. con distribución en una familia paramétrica de distribuciones, $\{F_\theta, \theta \in \Theta\}$. Sea X_1, \dots, X_n una m.a.s. de X . Sea g una función medible. Si $\hat{\theta}(X_1, \dots, X_n)$ es EMV de θ , entonces $g(\hat{\theta}(X_1, \dots, X_n))$ es EMV de $g(\theta)$.

Demostración. Sea $\lambda = g(\theta)$ y, fijada una realización muestral, $(x_1, \dots, x_n) \in \mathcal{X}^n$, notemos $\hat{\lambda} \equiv g(\hat{\theta}(x_1, \dots, x_n))$ (de esta manera, $\hat{\theta}(x_1, \dots, x_n) \in g^{-1}(\hat{\lambda})$).

Obtenemos la función de verosimilitud de la función paramétrica usando la Definición 0.2:

$$M_{x_1, \dots, x_n}(\hat{\lambda}) \stackrel{\text{def}}{=} \sup_{\theta \in g^{-1}(\hat{\lambda})} L_{x_1, \dots, x_n}(\theta) \stackrel{\hat{\theta} \in g^{-1}(\hat{\lambda})}{=} L_{x_1, \dots, x_n}(\hat{\theta}(x_1, \dots, x_n)) \quad (*)$$

donde en la última igualdad se ha usado que $\hat{\theta}(X_1, \dots, X_n)$ es EMV de θ , luego maximiza la función de verosimilitud de la Definición 0.1. Ahora, vemos que

$$\forall \lambda \in \Lambda, \quad M_{x_1, \dots, x_n}(\lambda) = \sup_{\theta \in g^{-1}(\lambda)} L_{x_1, \dots, x_n}(\theta) \leq \sup_{\theta \in \Theta} L_{x_1, \dots, x_n}(\theta) = L_{x_1, \dots, x_n}(\hat{\theta}(x_1, \dots, x_n)) \quad (**)$$

la última igualdad nuevamente por ser $\hat{\theta}(X_1, \dots, X_n)$ es EMV de θ . Deducimos entonces que

$$\forall \lambda \in \Lambda, \quad M_{x_1, \dots, x_n}(\lambda) \stackrel{(**)}{\leq} L_{x_1, \dots, x_n}(\hat{\theta}(x_1, \dots, x_n)) \stackrel{(*)}{=} M_{x_1, \dots, x_n}(\hat{\lambda})$$

Es decir, $\hat{\lambda} = g(\hat{\theta}(x_1, \dots, x_n))$ maximiza M_{x_1, \dots, x_n} , para cada $(x_1, \dots, x_n) \in \mathcal{X}^n$. Por la Definición 0.3, $g(\hat{\theta}(X_1, \dots, X_n))$ es el EMV de $\lambda = g(\theta)$. \square

b) Calcular la función de verosimilitud de

$$\lambda = (\theta - 1)^2$$

asociada a una realización muestral cuyo máximo valor es 3 si

$$f_{\theta}(x) = e^{x-\theta}, \quad x \leq \theta, \theta > 0.$$

Vemos que $\mathcal{X} =]-\infty, \theta]$. Sea $(x_1, \dots, x_n) \in \mathcal{X}^n$ tal que $x_{(n)} = 3$. Calculamos la función de densidad conjunta, asumiendo a partir de ahora que $\theta > 0$ (en otro caso, $f_{\theta}(x) = 0$).

$$f_{\theta}^n(x_1, \dots, x_n) \stackrel{\text{indep.}}{=} \prod_{i=1}^n f_{\theta}(x_i)$$

Ahora, vemos que $x \leq \theta \iff I_{\mathbb{R}_0^-}(x - \theta) = 1$ de donde se deduce que

$$\prod_{i=1}^n f_{\theta}(x_i) = \prod_{i=1}^n e^{x_i - \theta} \neq 0 \iff I_{\mathbb{R}_0^-}(x_i - \theta) = 1 \quad \forall i = 1, \dots, n$$

y a su vez

$$x_i \leq \theta \quad \forall i = 1, \dots, n \iff x_{(n)} \leq \theta \iff I_{\mathbb{R}_0^-}(x_{(n)} - \theta) = 1$$

luego

$$f_{\theta}^n(x_1, \dots, x_n) = \prod_{i=1}^n e^{x_i - \theta} I_{\mathbb{R}_0^-}(x_{(n)} - \theta) = e^{\left(\sum_{i=1}^n x_i - n\theta\right)} I_{\mathbb{R}_0^-}(x_{(n)} - \theta)$$

Por la Definición 0.1

$$L_{x_1, \dots, x_n}(\theta) = f_{\theta}^n(x_1, \dots, x_n) = e^{\left(\sum_{i=1}^n x_i - n\theta\right)} I_{\mathbb{R}_0^-}(x_{(n)} - \theta) \quad \forall \theta \in \Theta = \mathbb{R}^+$$

El enunciado nos dice que $\lambda = g(\theta) = (\theta - 1)^2$. Por la Definición 0.2

$$M_{x_1, \dots, x_n}(\lambda) = \sup_{\theta \in g^{-1}(\lambda)} L_{x_1, \dots, x_n}(\theta)$$

Resolvemos $(\theta - 1)^2 = \lambda$ para expresar θ explícitamente en función de λ . Vemos que $\lambda \geq 0$, y $(\theta - 1)^2 = \lambda \iff \theta - 1 = \pm \sqrt{\lambda} \iff \theta = 1 \pm \sqrt{\lambda}$.

A priori habría dos candidatos para cada λ . Sin embargo, por restricciones del problema, $3 = x_{(n)} \leq \theta$, lo que implica que

$$\theta = 1 + \sqrt{\lambda} \geq 3 \iff \sqrt{\lambda} \geq 2 \iff \lambda \geq 4$$

$$\theta = 1 - \sqrt{\lambda} \geq 3 \iff -\sqrt{\lambda} \geq 2 \iff \sqrt{\lambda} \leq -2$$

La última opción no puede darse por ser $\lambda \geq 0$, por tanto, nos quedamos con la primera. Así, si $\lambda \geq 4$ (en otro caso, $M_{x_1, \dots, x_n}(\lambda) = 0$)

$$M_{x_1, \dots, x_n}(\lambda) = L_{x_1, \dots, x_n}(1 + \sqrt{\lambda}) = e^{\left(\sum_{i=1}^n x_i - n(1 + \sqrt{\lambda}) \right)}$$

Aunque no se pide, como $e^{\sum_{i=1}^n x_i}$ es fijo, y $1 + \sqrt{\lambda}$ es creciente como función de λ y $e^{-n(1 + \sqrt{\lambda})}$ es decreciente como función de λ , y $M_{x_1, \dots, x_n}(\lambda) \neq 0 \iff \lambda \in [4, +\infty[$, entonces el máximo se alcanza en el extremo inferior del intervalo, es decir $\hat{\lambda}(x_1, \dots, x_n) = 4$. Esto puede comprobarse también con el Teorema 0.1 pues $L_{x_1, \dots, x_n}(\theta)$ es decreciente en $[x_{(n)}, +\infty[= [3, +\infty[$. Por el mismo razonamiento, $\hat{\theta}(x_1, \dots, x_n) = 3$, luego $\hat{\lambda} = (\hat{\theta} - 1)^2 = (3 - 1)^2 = 4$.

Ejercicio 4. Sea (X_1, \dots, X_n) una m.a.s. de X v.a. con función de densidad

$$f_\theta(x) = \frac{1}{\sqrt{8\theta}\sqrt{x-1}}, \quad 1 < x < 2\theta + 1. \quad (3)$$

Deducir el test más potente de tamaño arbitrario para contrastar

$$H_0 : \theta = \theta_0 \quad \text{frente a} \quad H_1 : \theta = \theta_1$$

siendo $\theta_1 < \theta_0$. Calcular la potencia.

Tenemos un contraste de hipótesis simple frente a hipótesis simple, por lo que sabemos por el Lema de Neyman-Pearson que el Test de Neyman-Pearson será el más potente de tamaño α , de la forma

$$\varphi(X_1, \dots, X_n) = \begin{cases} 1 & \text{si } \lambda(X_1, \dots, X_n) > k \\ \gamma & \text{si } \lambda(X_1, \dots, X_n) = k \\ 0 & \text{si } \lambda(X_1, \dots, X_n) < k \end{cases}$$

para ciertos $\gamma \in [0, 1]$, $k \in \mathbb{R}$ y

$$\lambda(X_1, \dots, X_n) = \frac{f_1^n(X_1, \dots, X_n)}{f_0^n(X_1, \dots, X_n)}$$

Definimos el espacio muestral y el espacio paramétrico, en ambos casos dependiente del parámetro θ . Si estamos en H_0 , entonces $\mathcal{X}_0 =]1, 2\theta_0 + 1[$, y $\Theta_0 = \{\theta_0\}$. Análogamente, si estamos en H_1 , entonces $\mathcal{X}_1 =]1, 2\theta_1 + 1[$, y $\Theta_1 = \{\theta_1\}$. Tenemos entonces que

$$\Theta = \Theta_0 \cup \Theta_1 = \{\theta_0, \theta_1\}$$

y como $\theta_1 < \theta_0 \iff 2\theta_1 + 1 < 2\theta_0 + 1$, entonces $]1, 2\theta_1 + 1[\subset]1, 2\theta_0 + 1[$ y

$$\mathcal{X} = \mathcal{X}_0 \cup \mathcal{X}_1 =]1, 2\theta_0 + 1[\cup]1, 2\theta_1 + 1[=]1, 2\theta_0 + 1[$$

Consecuentemente

$$\mathcal{X}^n = \{(x_1, \dots, x_n) \in \mathbb{R}^n : 1 < x_i < 2\theta_0 + 1 \quad \forall i = 1, \dots, n\} =$$

$$\{(x_1, \dots, x_n) \in \mathbb{R}^n : 1 < x_{(1)} \quad \wedge \quad x_{(n)} < 2\theta_0 + 1\}$$

Podemos considerar entonces $(x_1, \dots, x_n) \in \mathcal{X}^n$, y obtener la función conjunta $f_\theta^n(x_1, \dots, x_n)$, que es

$$f_\theta^n(x_1, \dots, x_n) \stackrel{\text{indep.}}{=} \prod_{i=1}^n \frac{1}{\sqrt{8\theta}\sqrt{x_i-1}}$$

Y vemos que

$$x < 2\theta + 1 \iff I_{\mathbb{R}^-}(x - (2\theta + 1)) = 1$$

luego

$$x_i < 2\theta + 1 \quad \forall i = 1, \dots, n \iff x_{(n)} < 2\theta + 1 \iff I_{\mathbb{R}^-}(x_{(n)} - (2\theta + 1)) = 1$$

Por tanto

$$f_{\theta}^n(x_1, \dots, x_n) = \prod_{i=1}^n \frac{1}{\sqrt{8\theta}\sqrt{x_i-1}} I_{\mathbb{R}^-}(x_{(n)} - (2\theta + 1)) =$$

$$(8\theta)^{-n/2} \prod_{i=1}^n \frac{1}{\sqrt{x_i-1}} I_{\mathbb{R}^-}(x_{(n)} - (2\theta + 1)) = 8^{-n/2} \theta^{-n/2} \prod_{i=1}^n \frac{1}{\sqrt{x_i-1}} I_{\mathbb{R}^-}(x_{(n)} - (2\theta + 1))$$

Se tiene entonces que

$$f_0^n(x_1, \dots, x_n) = 8^{-n/2} \theta_0^{-n/2} \prod_{i=1}^n \frac{1}{\sqrt{x_i-1}} I_{\mathbb{R}^-}(x_{(n)} - (2\theta_0 + 1)) =$$

$$8^{-n/2} \theta_0^{-n/2} \prod_{i=1}^n \frac{1}{\sqrt{x_i-1}} \quad \forall (x_1, \dots, x_n) \in \mathcal{X}^n$$

$$f_1^n(x_1, \dots, x_n) = 8^{-n/2} \theta_1^{-n/2} \prod_{i=1}^n \frac{1}{\sqrt{x_i-1}} I_{\mathbb{R}^-}(x_{(n)} - (2\theta_1 + 1)) \quad \forall (x_1, \dots, x_n) \in \mathcal{X}^n$$

y podemos obtener $\lambda(x_1, \dots, x_n)$, con $(x_1, \dots, x_n) \in \mathcal{X}^n$:

$$\lambda(x_1, \dots, x_n) = \frac{f_1^n(x_1, \dots, x_n)}{f_0^n(x_1, \dots, x_n)} =$$

$$\frac{8^{-n/2} \theta_1^{-n/2} \prod_{i=1}^n \frac{1}{\sqrt{x_i-1}} I_{\mathbb{R}^-}(x_{(n)} - (2\theta_1 + 1))}{8^{-n/2} \theta_0^{-n/2} \prod_{i=1}^n \frac{1}{\sqrt{x_i-1}}} = \frac{\begin{cases} 8^{-n/2} \theta_1^{-n/2} \prod_{i=1}^n \frac{1}{\sqrt{x_i-1}} & \text{si } x_{(n)} < 2\theta_1 + 1 \\ 0 & \text{si } x_{(n)} \geq 2\theta_1 + 1 \end{cases}}{8^{-n/2} \theta_0^{-n/2} \prod_{i=1}^n \frac{1}{\sqrt{x_i-1}}}$$

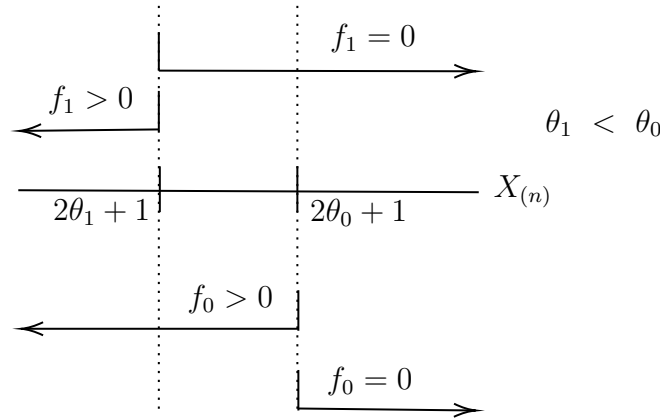
Ahora, si $x_{(n)} < 2\theta_1 + 1$, simplificamos

$$\frac{8^{-n/2} \theta_1^{-n/2} \prod_{i=1}^n \frac{1}{\sqrt{x_i-1}}}{8^{-n/2} \theta_0^{-n/2} \prod_{i=1}^n \frac{1}{\sqrt{x_i-1}}} = \left(\frac{\theta_1}{\theta_0}\right)^{-n/2} = \left(\frac{\theta_0}{\theta_1}\right)^{n/2}$$

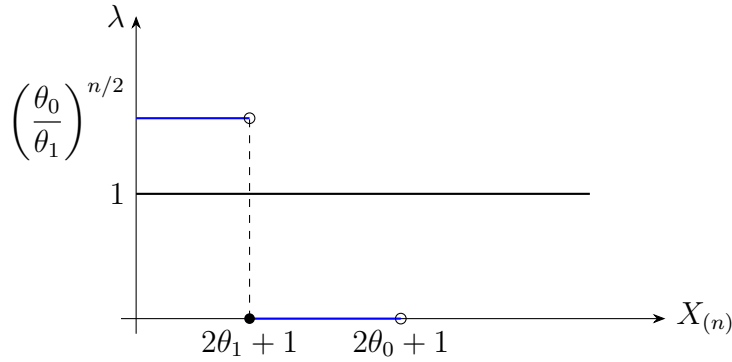
de donde

$$\lambda(x_1, \dots, x_n) = \frac{f_1^n(x_1, \dots, x_n)}{f_0^n(x_1, \dots, x_n)} = \begin{cases} \left(\frac{\theta_0}{\theta_1}\right)^{n/2} & \text{si } x_{(n)} < 2\theta_1 + 1 \\ 0 & \text{si } x_{(n)} \geq 2\theta_1 + 1 \end{cases} \quad \forall (x_1, \dots, x_n) \in \mathcal{X}^n$$

Gráficamente, como $\theta_1 < \theta_0$:



La semirrecta en que $f_0 = 0$, que se corresponde con la condición $x_{(n)} \geq 2\theta_0 + 1$, no nos interesa ya que $(x_1, \dots, x_n) \notin \mathcal{X}^n$. Gráficamente, la situación en la que estamos es la siguiente:



Tenemos que $k \in \left\{0, \left(\frac{\theta_0}{\theta_1}\right)^{n/2}\right\}$, luego distinguimos entre estos dos casos.

Si $\boxed{k = 0}$, entonces el test será:

$$\varphi(X_1, \dots, X_n) = \begin{cases} 1 & \text{si } \lambda(X_1, \dots, X_n) > k \iff X_{(n)} < 2\theta_1 + 1 \\ \gamma & \text{si } \lambda(X_1, \dots, X_n) = k \iff X_{(n)} \geq 2\theta_1 + 1 \\ 0 & \text{si } \lambda(X_1, \dots, X_n) < k \text{ nunca} \end{cases}$$

es decir:

$$\varphi(X_1, \dots, X_n) = \begin{cases} 1 & \text{si } X_{(n)} < 2\theta_1 + 1 \\ \gamma & \text{si } X_{(n)} \geq 2\theta_1 + 1 \end{cases}$$

Determinamos γ imponiendo tamaño α :

$$\alpha \stackrel{\text{def}}{=} \sup_{\theta \in \Theta_0} \beta_\varphi(\theta) = \sup_{\theta \in \Theta_0} E_\theta[\varphi(X_1, \dots, X_n)] = E_{\theta_0}[\varphi(X_1, \dots, X_n)] = 1 \cdot P_{\theta_0}[X_{(n)} < 2\theta_1 + 1] + \gamma P_{\theta_0}[X_{(n)} \geq 2\theta_1 + 1]$$

Para calcular las probabilidades, obtenemos la función de distribución $F_X(t)$:

$$F_X(t) \stackrel{\text{def}}{=} \int_1^t \frac{1}{\sqrt{8\theta}\sqrt{x-1}} dx = \frac{1}{\sqrt{8\theta}} \int_1^t \frac{1}{\sqrt{x-1}} dx = \frac{1}{\sqrt{8\theta}} [2\sqrt{x-1}]_1^t = \frac{2\sqrt{t-1}}{\sqrt{8\theta}} = \frac{\sqrt{t-1}}{\sqrt{2\theta}}$$

Sabemos por teoría que, para $T = X_{(n)}$, la distribución del máximo verifica

$$P_{\theta}[T < t] = F_T(t) = (F_X(t))^n = \left(\frac{\sqrt{t-1}}{\sqrt{2\theta}} \right)^n = \left(\sqrt{\frac{t-1}{2\theta}} \right)^n = \left(\frac{t-1}{2\theta} \right)^{n/2}$$

Por lo tanto,

$$P_{\theta_0}[T < 2\theta_1 + 1] = \left(\frac{\theta_1}{\theta_0} \right)^{n/2}$$

y

$$P_{\theta_0}[T \geq 2\theta_1 + 1] = 1 - P_{\theta_0}[T < 2\theta_1 + 1] = 1 - \left(\frac{\theta_1}{\theta_0} \right)^{n/2}$$

de donde

$$\alpha = 1 \cdot P_{\theta_0}[X_{(n)} < 2\theta_1 + 1] + \gamma P_{\theta_0}[X_{(n)} \geq 2\theta_1 + 1] = \left(\frac{\theta_1}{\theta_0} \right)^{n/2} + \gamma \left(1 - \left(\frac{\theta_1}{\theta_0} \right)^{n/2} \right) \iff$$

$$0 \leq \gamma = \frac{\alpha - \left(\frac{\theta_1}{\theta_0} \right)^{n/2}}{1 - \left(\frac{\theta_1}{\theta_0} \right)^{n/2}} \leq 1 \iff \alpha \geq \left(\frac{\theta_1}{\theta_0} \right)^{n/2}$$

y el test resultante es:

$$\varphi(X_1, \dots, X_n) = \begin{cases} 1 & \text{si } X_{(n)} < 2\theta_1 + 1 \\ \frac{\alpha - \left(\frac{\theta_1}{\theta_0} \right)^{n/2}}{1 - \left(\frac{\theta_1}{\theta_0} \right)^{n/2}} & \text{si } X_{(n)} \geq 2\theta_1 + 1 \end{cases}$$

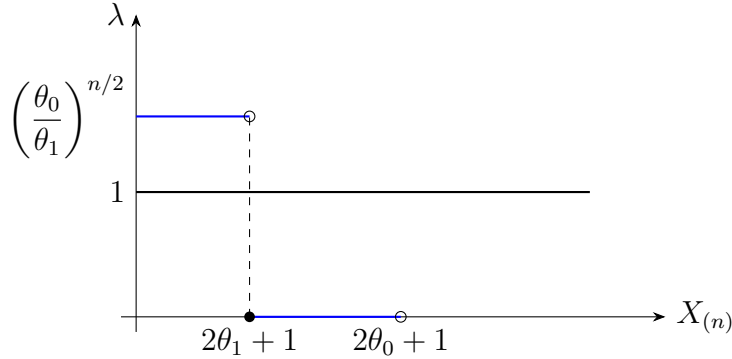
con potencia (en $\Theta_1 = \{\theta_1\}$):

$$\beta_{\varphi}(\theta_1) = E_{\theta_1}[\varphi(X_1, \dots, X_n)] = P_{\theta_1}[T < 2\theta_1 + 1] + \frac{\alpha - \left(\frac{\theta_1}{\theta_0} \right)^{n/2}}{1 - \left(\frac{\theta_1}{\theta_0} \right)^{n/2}} P_{\theta_1}[T \geq 2\theta_1 + 1]$$

Como $P_{\theta_1}[T < 2\theta_1 + 1] = 1$ y $P_{\theta_1}[T \geq 2\theta_1 + 1] = 1 - P_{\theta_1}[T < 2\theta_1 + 1] = 1 - 1 = 0$, entonces

$$\beta_{\varphi}(\theta_1) = 1$$

Si $k = \left(\frac{\theta_0}{\theta_1}\right)^{n/2}$, el test será, mirando nuevamente la misma gráfica



el que sigue:

$$\varphi(X_1, \dots, X_n) = \begin{cases} 1 & \text{si } \lambda(X_1, \dots, X_n) > k \text{ nunca} \\ \gamma & \text{si } \lambda(X_1, \dots, X_n) = k \iff X_{(n)} < 2\theta_1 + 1 \\ 0 & \text{si } \lambda(X_1, \dots, X_n) < k \iff X_{(n)} \geq 2\theta_1 + 1 \end{cases}$$

es decir:

$$\varphi(X_1, \dots, X_n) = \begin{cases} \gamma & \text{si } X_{(n)} < 2\theta_1 + 1 \\ 0 & \text{si } X_{(n)} \geq 2\theta_1 + 1 \end{cases}$$

Determinamos γ igual que antes imponiendo tamaño α :

$$\alpha \stackrel{\text{def}}{=} \sup_{\theta \in \Theta_0} \beta_\varphi(\theta) = \sup_{\theta \in \Theta_0} E_\theta[\varphi(X_1, \dots, X_n)] = E_{\theta_0}[\varphi(X_1, \dots, X_n)] =$$

$$\gamma \cdot P_{\theta_0}[X_{(n)} < 2\theta_1 + 1] + 0 \cdot P_{\theta_0}[X_{(n)} \geq 2\theta_1 + 1] = \gamma \cdot P_{\theta_0}[X_{(n)} < 2\theta_1 + 1]$$

Ya sabemos del caso anterior que

$$P_{\theta_0}[T < 2\theta_1 + 1] = \left(\frac{\theta_1}{\theta_0}\right)^{n/2}$$

luego

$$\alpha = \gamma \cdot P_{\theta_0}[X_{(n)} < 2\theta_1 + 1] = \gamma \left(\frac{\theta_1}{\theta_0}\right)^{n/2} \iff$$

$$0 \leq \gamma = \frac{\alpha}{\left(\frac{\theta_1}{\theta_0}\right)^{n/2}} = \alpha \left(\frac{\theta_0}{\theta_1}\right)^{n/2} \leq 1 \iff \alpha \leq \left(\frac{\theta_1}{\theta_0}\right)^{n/2}$$

y el test resultante es:

$$\varphi(X_1, \dots, X_n) = \begin{cases} \alpha \left(\frac{\theta_0}{\theta_1}\right)^{n/2} & \text{si } X_{(n)} < 2\theta_1 + 1 \\ 0 & \text{si } X_{(n)} \geq 2\theta_1 + 1 \end{cases}$$

con potencia (en $\Theta_1 = \{\theta_1\}$):

$$\begin{aligned}\beta_\varphi(\theta_1) &= E_{\theta_1}[\varphi(X_1, \dots, X_n)] = \alpha \left(\frac{\theta_0}{\theta_1} \right)^{n/2} \cdot P_{\theta_1}[T < 2\theta_1 + 1] + 0 \cdot P_{\theta_1}[T \geq 2\theta_1 + 1] = \\ &\alpha \left(\frac{\theta_0}{\theta_1} \right)^{n/2} \cdot P_{\theta_1}[T < 2\theta_1 + 1]\end{aligned}$$

Igual que en el caso anterior $P_{\theta_1}[T < 2\theta_1 + 1] = 1$, luego

$$\beta_\varphi(\theta_1) = \alpha \left(\frac{\theta_0}{\theta_1} \right)^{n/2}$$

Ejercicio 5.

a) Test de Kolmogorov–Smirnov.

i) Plantear el problema de contraste.

Sea una función de distribución específica F_0 , y sea (X_1, \dots, X_n) una m.a.s. de una v.a. X continua que se distribuye según una función de distribución F que es completamente desconocida. El contraste a resolver es

$$\begin{cases} H_0 : F = F_0 \\ H_1 : F \neq F_0 \end{cases}$$

ii) Dar el valor del estadístico.

El estadístico que se usa para resolver el problema es el estadístico de Kolmogorov-Smirnov

$$D(X_1, \dots, X_n) = \sup_{x \in \mathbb{R}} |F_{X_1, \dots, X_n}^*(x) - F_0(x)|$$

iii) Enunciar el teorema que justifica su uso.

El test se basa en el teorema de Glivenko-Cantelli:

Teorema 0.2 (de Glivenko-Cantelli). *Sea $\{X_n\}_{n \in \mathbb{N}}$ una sucesión de v.a.i.i.d. con función de distribución común F . Si F_{X_1, \dots, X_n}^* es la función de distribución muestral asociada a la m.a.s. (X_1, \dots, X_n) , se verifica que F_{X_1, \dots, X_n}^* converge casi seguramente y uniformemente a la función de distribución de X , F .*

$$P \left\{ \lim_{n \rightarrow +\infty} \sup_{x \in \mathbb{R}} |F_{X_1, \dots, X_n}^*(x) - F(x)| = 0 \right\} = 1$$

iv) Ventajas frente al test χ^2 .

Se asume que nos referimos al test χ^2 de Pearson.

- 1) El test de Kolmogorov-Smirnov no necesita hacer particiones de los datos, mientras que el test χ^2 de Pearson sí.
 - 2) Para v.a. continuas, es más apropiado usar el test de Kolmogorov-Smirnov que el test χ^2 de Pearson.
 - 3) Bajo H_0 , si F_0 es continua, la distribución del estadístico de Kolmogorov-Smirnov no depende de F_0 , mientras que el test χ^2 de Pearson es asintótico.
- b) Se cuentan el número de tutorías a lo largo de un curso por 50 profesores. Se quiere contrastar si el número de tutorías por profesor se puede describir mediante una distribución de Poisson.

Número de tutorías	0	1	2	3	4	5
Número de profesores	2	5	10	14	12	7

En este caso, como la variable aleatoria es discreta, y tenemos frecuencias, es más apropiado usar el test χ^2 de Pearson. Sea

$$X \equiv \text{“Número de tutorías por un profesor”}$$

El contraste a resolver es

$$\begin{cases} H_0 : X \rightsquigarrow \mathcal{P}(\lambda) \\ H_1 : X \not\rightsquigarrow \mathcal{P}(\lambda) \end{cases} \quad \lambda > 0$$

Vemos que la hipótesis nula es compuesta, luego primeramente debemos estimar el valor del parámetro λ . Sabemos que el EMV de λ es la media muestral. Así

$$\hat{\lambda} = \bar{X} = \frac{0 \cdot 2 + 1 \cdot 5 + 2 \cdot 10 + 3 \cdot 14 + 4 \cdot 12 + 5 \cdot 7}{50} = \frac{150}{50} = 3$$

El contraste adaptado sería

$$\begin{cases} H_0 : X \rightsquigarrow \mathcal{P}(3) \\ H_1 : X \not\rightsquigarrow \mathcal{P}(3) \end{cases}$$

Denotemos por N_1, \dots, N_k las frecuencias observadas en las k clases consideradas, y por

$$\hat{p}_i = P_{\hat{\lambda}}(X \in A_i), \quad i = 1, \dots, k$$

las probabilidades teóricas bajo H_0 con el parámetro λ estimado por $\hat{\lambda}$.

El estadístico de contraste viene dado por

$$\hat{\chi}(N_1, \dots, N_k) = \sum_{i=1}^k \frac{(N_i - n\hat{p}_i)^2}{n\hat{p}_i}$$

Como el parámetro se ha estimado a partir de los mismos datos, la distribución asintótica bajo H_0 es

$$\hat{\chi}(N_1, \dots, N_k) \rightsquigarrow_{H_0} \chi^2(k - q - 1)$$

con $q = 1$ el número de parámetros estimados.

Por teoría, para poder aplicar el test hay que verificar que

$$E_i^* = n\hat{p}_i \geq 5 \quad \forall i = 1, \dots, k, \quad n = 50, \quad \hat{p}_i = P[X = i] = e^{-3} \frac{3^i}{i!}$$

Primero vamos tanteando (no se ponen a propósito E_0^* ni E_6^*):

$$E_1^* = 50 \cdot e^{-3} \frac{3^1}{1!} \approx 7,47$$

$$E_2^* = 50 \cdot e^{-3} \frac{3^2}{2!} \approx 11,2$$

$$E_3^* = 50 \cdot e^{-3} \frac{3^3}{3!} \approx 11,2$$

$$E_4^* = 50 \cdot e^{-3} \frac{3^4}{4!} \approx 8,4$$

$$E_5^* = 50 \cdot e^{-3} \frac{3^5}{5!} \approx 5,05$$

En este punto³, como

$$E_0^* = 50 \cdot \hat{p}_0 = 50 \cdot e^{-3} \frac{3^0}{0!} \approx 2,49$$

$$E_6^* = 50 \cdot e^{-3} \frac{3^6}{6!} \approx 2,52$$

debemos aquí agrupar los mayores o iguales que 5. Por ejemplo, podemos agrupar 0 y 1, y no considerar E_6^* , y en su lugar, considerar

$$E_{\geq 6}^* = nP_{\hat{\lambda}}(X \geq 6) = n(1 - P_{\hat{\lambda}}(X < 6)) = n - \sum_{i=0}^5 nP_{\hat{\lambda}}(X = i) = n - \sum_{i=0}^5 E_i^* \approx$$

$$50 - (2,49 + 7,47 + 11,2 + 11,2 + 8,4 + 5,05) = 4,19 < 5$$

que sigue siendo menor estricto que 5, por lo que agrupamos la cola derecha a partir del 5, y ahora sí

$$E_{\geq 5}^* = nP_{\hat{\lambda}}(X \geq 5) = n - \sum_{i=0}^4 E_i^* = 50 - \left(\sum_{i=0}^4 E_i^* - E_5^* \right) = 50 - (45,81 - 5,05) = 50 - 40,76 =$$

$$9,24 \geq 5$$

³hay que particionar el espacio muestral de la Poisson, que es $\mathbb{N} \cup \{0\}$, en grupos que verifiquen las condiciones del test χ^2 de Pearson, por eso las consideraciones siguientes.

Una partición sería la siguiente

$$A_1 = \{0, 1\}, \quad A_i = \{i\}, \quad A_5 = \{\geq 5\}, \quad i = 2, 3, 4$$

En este caso, $k = 5$ (número de clases tras agrupar), luego $\hat{\chi}^2(N_1, \dots, N_k) \rightsquigarrow \chi^2(3)$. Las frecuencias observadas, denotadas por $O_i, i = 1, \dots, k$, son

$$O_1 = N_0 + N_1 = 2 + 5 = 7, \quad O_2 = 10, \quad O_3 = 14, \quad O_4 = 12, \quad O_5 = 7$$

Las frecuencias esperadas son

$$E_1 = E_0^* + E_1^* \approx 2,49 + 7,47 = 9,96, \quad E_2 = E_2^* \approx 11,2 \quad E_3 = E_3^* \approx 11,2 \quad E_4 = E_4^* \approx 8,4$$

$$E_5 = 50 - \sum_{i=1}^4 E_i \approx 50 - (9,96 + 11,2 + 11,2 + 8,4) = 9,24$$

Obtenemos

$$\begin{aligned} \chi_{exp}^2 &= \sum_{i=1}^5 \frac{(O_i - E_i)^2}{E_i} = \frac{(7 - 9,96)^2}{9,96} + \frac{(10 - 11,2)^2}{11,2} + \frac{(14 - 11,2)^2}{11,2} + \frac{(12 - 8,4)^2}{8,4} + \\ &\quad \frac{(7 - 9,24)^2}{9,24} \approx 3,79 \end{aligned}$$

El test asintótico de tamaño α es

$$\varphi(X_1, \dots, X_n) = \begin{cases} 1 & \text{si } \hat{\chi}^2(N_1, \dots, N_k) \geq \chi_{k-1;\alpha}^2 \\ 0 & \text{si } \hat{\chi}^2(N_1, \dots, N_k) < \chi_{k-1;\alpha}^2 \end{cases}$$

con

$$p - \text{valor} = P_{H_0}[\hat{\chi}^2(N_1, \dots, N_k) \geq \chi_{exp}^2] \approx_{n \rightarrow +\infty} P[\chi^2(k - q - 1) \geq \chi_{exp}^2]$$

y χ_{exp}^2 el valor del estadístico obtenido con la muestra observada. Usando que $k - q - 1 = 3$, obtenemos

$$p - \text{valor} \approx P[\chi^2(3) \geq 3,79] \approx 0,3$$

Como el $p - \text{valor}$ es grande (respecto a los niveles habituales de significación), se acepta H_0 , por lo que puede suponerse que el número de tutorías por profesor se puede describir mediante una distribución de Poisson.