

**PROBABILIDAD Y ESTADÍSTICA  
EXAMEN JULIO 2005**

**DATOS DEL ESTUDIANTE**

No. de Examen	Apellidos y Nombres	Cédula

- **La duración total del examen es de 3 horas y media.**
- **El puntaje mínimo para aprobar es 50 puntos.**
- **Publicación de resultados: viernes 5 de agosto - 14:00 hs.**
- **Muestra de exámenes: martes 9 de agosto - 16:00 hs.**

**Problema 1 (35 puntos)**

Considere una moneda cargada de manera que

$$\mathbf{P}(\text{Cara}) = q \quad \text{y} \quad \mathbf{P}(\text{Número}) = 1 - q,$$

donde  $q \in (0, 1)$ .

Sea  $X$  la variable aleatoria que cuenta el número de veces que hay que tirar la moneda hasta que hayan salido los dos resultados (por ejemplo, si la secuencia de tiradas es:  $CCCN$ , entonces  $X = 4$ ; si la secuencia de tiradas es:  $NNC$ , entonces  $X = 3$ ).

- a) **(10 puntos)** Calcule la función de probabilidad de la variable  $X$ .
- b) **(8 puntos)** Calcule la probabilidad de que la primer tirada haya sido *Cara* dado que  $X = 10$ .
- c) **(10 puntos)** Pruebe que el valor esperado de  $X$  es

$$\mathbf{E}(X) = \frac{1}{q(1-q)} - 1.$$

- d) **(7 puntos)** Suponga que se repite  $n$  veces el procedimiento y que el número medio de tiradas hasta que hayan salido los dos resultados es  $\bar{X}_n = 5.25$ . Estime el valor del parámetro  $q$ , sabiendo que es más probable obtener *Cara* que *Número*.

**Problema 2 (30 puntos)**

Considere una sucesión de variables aleatorias  $X_1, X_2, \dots, X_n$  i.i.d. con distribución uniforme en el intervalo  $[\theta - 1, \theta + 1]$ , donde  $\theta$  es un parámetro desconocido. Denotamos  $\bar{X}_n$  el promedio de estas variables.

- a) (7 puntos) Calcule  $\mathbf{E}(\bar{X}_n)$  y  $\mathbf{Var}(\bar{X}_n)$ .
- b) (8 puntos) Construya un estimador  $T_n$  del parámetro  $\theta$  que sea consistente e insegado y calcule su error cuadrático medio, esto es,  $\mathbf{E}([T_n - \theta]^2)$ .
- c) (8 puntos) Sabiendo que  $n = 300$  y  $\bar{X}_n = 2.5$ , construya un intervalo de confianza aproximado al 95% para el parámetro  $\theta$ .
- d) (7 puntos) Calcule  $\mathbf{P}(\max\{X_1, X_2, \dots, X_n\} \leq \theta + \frac{1}{2})$ .

**Problema 3 (35 puntos)**

**Nota: En todas las pruebas de hipótesis utilice el siguiente criterio de decisión: se acepta la hipótesis nula si el  $p$ -valor es superior a 0.1**

Los siguientes datos corresponden a los tiempos de duración (medidos en meses) de lamparitas marca ACME:

3.33	6.71	2.53	7.15	16.82	3.56	0.17	2.15	3.51	7.24
------	------	------	------	-------	------	------	------	------	------

- a) (7 puntos) Implemente el test de correlación de rangos de Spearman para estudiar la aleatoriedad de la muestra.
- b) (10 puntos) Estudie si es razonable suponer que los datos corresponden a una distribución exponencial (realice una sola prueba de hipótesis).
- c) (8 puntos) ¿Es razonable suponer que la mediana de la muestra es  $m = 4$ ? (realice una sola prueba de hipótesis).
- d) (10 puntos) Se dispone ahora de una nueva muestra *i.i.d. e independiente* de la anterior (no hay que verificar estos supuestos), correspondiente a tiempos de duración de lamparitas de marca desconocida:

5.6	3.03	1.46	16.52	0.37	0.58	3.38	9.15	0.9	4.44
-----	------	------	-------	------	------	------	------	-----	------

Implemente un test de comparación de muestras para concluir si es razonable suponer que los nuevos datos tienen la misma distribución que los anteriores.

## SOLUCIÓN

### Problema 1

a) Consideramos los sucesos

$$\begin{aligned} C &= \text{“salió Cara en el primer lanzamiento”} \\ N &= \text{“salió Número en el primer lanzamiento”} \end{aligned}$$

Luego, para  $n \geq 2$ :

$$\begin{aligned} \mathbf{P}(X = n) &= \mathbf{P}([X = n] \cap C) + \mathbf{P}([X = n] \cap N) \\ &= \mathbf{P}([X = n] | C)\mathbf{P}(C) + \mathbf{P}([X = n] | N)\mathbf{P}(N). \end{aligned}$$

Ahora bien, si salió Cara en el primer lanzamiento, para que  $X$  sea igual a  $n$  hay que tener Cara en los siguientes  $n - 2$  lanzamientos y en el último debe salir Número, esto es

$$\mathbf{P}([X = n] | C) = q^{n-2} (1 - q)$$

De la misma manera

$$\mathbf{P}([X = n] | N) = (1 - q)^{n-2} q.$$

Así que

$$\mathbf{P}(X = n) = q^{n-1} (1 - q) + (1 - q)^{n-1} q \quad \forall n \geq 2. \quad (1)$$

**Otra manera:** Si  $X = n$ , para  $n \geq 2$ , entonces ha ocurrido uno u otro de los siguientes eventos mutuamente excluyentes:

- $A = CCCC \dots N$ , esto es,  $n - 1$  Caras y al final Número,
- $B = NNNN \dots C$ , esto es,  $n - 1$  Números y al final Cara.

Está claro que  $\mathbf{P}(A) = q^{n-1}(1 - q)$  y que  $\mathbf{P}(B) = (1 - q)^{n-1}q$ . Por lo tanto:

$$\mathbf{P}(X = n) = \mathbf{P}(A) + \mathbf{P}(B) = q^{n-1} (1 - q) + (1 - q)^{n-1} q \quad \forall n \geq 2.$$

b) De la definición de probabilidad condicional tenemos

$$\mathbf{P}(C | [X = 10]) = \frac{\mathbf{P}(C \cap [X = 10])}{\mathbf{P}([X = 10])},$$

de manera que usando (1) y las probabilidades calculadas queda:

$$\mathbf{P}(C | [X = 10]) = \frac{q^9(1 - q)}{q^9(1 - q) + (1 - q)^9q}.$$

c)

$$\begin{aligned} \mathbf{E}(X) &= \sum_{n=2}^{\infty} n \mathbf{P}(X = n) = \sum_{n=2}^{\infty} n \left[ q^{n-1} (1-q) + (1-q)^{n-1} q \right] \\ &= \sum_{n=2}^{\infty} n q^{n-1} (1-q) + \sum_{n=2}^{\infty} n (1-q)^{n-1} q. \end{aligned}$$

Sabemos que si  $Y \sim \text{Geo}(p)$ , entonces

$$\mathbf{E}(Y) = \sum_{n=1}^{\infty} n (1-p)^{n-1} p = \frac{1}{p},$$

por lo tanto

$$\sum_{n=2}^{\infty} n (1-p)^{n-1} p = \frac{1}{p} - p.$$

Usando este resultado obtenemos

$$\mathbf{E}(X) = \frac{1}{(1-q)} - (1-q) + \frac{1}{q} - q = \frac{1}{q(1-q)} - 1$$

d) Por el método de los momentos

$$\mathbf{E}(X) = \bar{X}_n,$$

esto es

$$\frac{1}{q(1-q)} - 1 = 5.25 \Leftrightarrow \begin{cases} q = 0.2 \\ q = 0.8 \end{cases}$$

Por otra parte sabemos que es más probable obtener *Cara* que *Número*, así que se cumple

$$q > 1 - q \Leftrightarrow \frac{1}{2} < q,$$

de manera que

$$q = 0.8$$

### Problema 2

a)

$$\begin{aligned} \mathbf{E}(\bar{X}_n) &= \mathbf{E}\left(\frac{X_1 + X_2 + \dots + X_n}{n}\right) = \frac{1}{n} (\mathbf{E}(X_1) + \mathbf{E}(X_2) + \dots + \mathbf{E}(X_n)) \\ &= \frac{1}{n} n \mathbf{E}(X) = \mathbf{E}(X) = \frac{\theta + 1 + \theta - 1}{2} = \theta. \end{aligned}$$

Por otra parte, usando que las variables son independientes:

$$\begin{aligned} \mathbf{Var}(\bar{X}_n) &= \mathbf{Var}\left(\frac{X_1 + X_2 + \dots + X_n}{n}\right) = \frac{1}{n^2} (\mathbf{Var}(X_1) + \mathbf{Var}(X_2) + \dots + \mathbf{Var}(X_n)) \\ &= \frac{1}{n} \mathbf{Var}(X) = \frac{1}{n} \frac{(\theta + 1 - (\theta - 1))^2}{12} = \frac{1}{3n}. \end{aligned}$$

- b) Para que  $T_n$  sea un estimador insesgado y consistente de  $\theta$  debe cumplir  $\mathbf{E}(T_n) = \theta$  y  $T_n \rightarrow \theta$ . El promedio cumple la primer condición, como hemos visto en la parte anterior, y la segunda es precisamente la Ley Fuerte de los Grandes Números. Por lo tanto tomamos

$$T_n = \bar{X}_n.$$

Con esto, el error cuadrático medio resulta:

$$\mathbf{E}([T_n - \theta]^2) = \mathbf{E}([\bar{X}_n - \mathbf{E}(\bar{X}_n)]^2) = \mathbf{Var}(\bar{X}_n) = \frac{1}{3n}.$$

- c) Por el Teorema Central del Límite sabemos que

$$\mathbf{P} \left( -z_{\frac{\alpha}{2}} \leq \frac{\bar{X}_n - \mathbf{E}(\bar{X}_n)}{\sqrt{\mathbf{Var}(\bar{X}_n)}} \leq z_{\frac{\alpha}{2}} \right) \approx 1 - \alpha$$

y por lo tanto

$$\mathbf{P} \left( \bar{X}_n - \sqrt{\frac{1}{3n}} z_{\frac{\alpha}{2}} \leq \theta \leq \bar{X}_n + \sqrt{\frac{1}{3n}} z_{\alpha} \right) \approx 1 - \alpha.$$

En este caso

$$1 - \alpha = 0.95 \Leftrightarrow \alpha = 0.05$$

$$z_{\frac{\alpha}{2}} = z_{0.025} = 1.95.$$

Así, un intervalo de confianza aproximado al 95% para el parámetro  $\theta$  es

$$2.5 - \sqrt{\frac{1}{3(300)}} (1.96) \leq \theta \leq 2.5 + \sqrt{\frac{1}{3(300)}} (1.96),$$

esto es

$$I = [2.4347, 2.5653].$$

- d)

$$\mathbf{P} \left( \max\{X_1, X_2, \dots, X_n\} \leq \theta + \frac{1}{2} \right) = \left( \mathbf{P} \left( X \leq \theta + \frac{1}{2} \right) \right)^n = \left( \int_{\theta-1}^{\theta+\frac{1}{2}} \frac{1}{2} dx \right)^n = \left( \frac{3}{4} \right)^n.$$

### Problema 3

a) **Test de rangos de Spearman**

Se ordenan los datos de menor a mayor. La tabla muestra los datos ordenados  $X_i^*$ , los índices  $i$  (esto es, el lugar que ocupaban los datos originalmente) y los rangos  $R(X_i)$ .

$X_i^*$	$i$	$R(X_i)$
0.17	7	1
2.15	8	2
2.53	3	3
3.33	1	4
3.51	9	5
3.56	6	6
6.71	2	7
7.15	4	8
7.24	10	9
16.82	5	10

El estadístico del test resulta

$$r_s = 1 - 6 \frac{\sum_{i=1}^{10} (R(X_i) - i)^2}{10(10^2 - 1)} = 0.0061$$

La tabla del test para  $n = 10$  muestra que  $\alpha^* = 0.5$ . Es razonable, entonces, suponer que la muestra es aleatoria.

- b) Para estudiar si es razonable suponer que los datos corresponden a la distribución exponencial realizamos el test de ajuste de Lilliefors.

**Test de Lilliefors**

El estadístico del test es

$$D_n = \sup_{t \in \mathbf{R}} |F(t) - F_n(t)|$$

donde  $F_n(t)$  es la función de distribución empírica de la muestra y  $F(t)$  es la distribución exponencial de parámetro  $\lambda = 1/\bar{X}_{10} = 0.18808$ . En este caso el valor que se obtiene para el estadístico es  $D_n = 0.2326$ .

La tabla del test de Lilliefors para  $n = 10$  nos da  $\alpha^* > 0.20$  y por lo tanto es razonable suponer que la muestra ajusta a la distribución  $\exp(0.18808)$ .

- c) Realizamos el Test de Signos para estudiar si es razonable suponer que la mediana de los datos es  $m = 4$ .

El estadístico del test es

$$U = \sum_{i=1}^{10} \mathbf{1}_{\{X_i \leq m\}}$$

En este caso  $U = 6$ , y utilizando la tabla de la distribución  $\text{Bin}(10,0.5)$  o la tabla del test de signos se tiene que  $\alpha^* = 0.8281$ . Por lo tanto es razonable suponer que la mediana es  $m = 4$ .

**d) Test de Kolmogorov-Smirnov de comparación de muestras**

El estadístico del test es

$$D = \sup_{t \in \mathbf{R}} |F_m^X(t) - F_n^Y(t)|$$

donde  $F_m^X(t)$  y  $F_n^Y(t)$  son las funciones de distribución empírica de la primera y de la segunda muestra respectivamente. El valor que se obtiene para el estadístico es  $D = 0.30$

La tabla del test para  $m = n = 10$  nos da  $\alpha^* > 0.20$  y por lo tanto es razonable suponer que las dos muestras tienen la misma distribución.