

**PROBABILIDAD Y ESTADÍSTICA
SEGUNDO PARCIAL 2005**

DATOS DEL ESTUDIANTE

No. de Parcial	Apellidos y Nombres	Cédula

- **La duración total de la prueba es de 3 horas y media.**
- **Publicación de resultados: miércoles 20 de julio - 18:00 hs.**
- **Muestra de parciales: viernes 22 de julio - 16:00 hs.**

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

Problema 1 (35 puntos)

Un sistema de información está formado por dos servidores. Cuando un cliente accede al sistema es asignado con probabilidad p al servidor A y con probabilidad $(1 - p)$ al servidor B. De esta manera la variable aleatoria X que representa el tiempo de servicio de un cliente tiene una distribución cuya densidad es:

$$f_X(x) = \begin{cases} p \frac{1}{\theta_1} e^{-\frac{x}{\theta_1}} + (1-p) \frac{1}{\theta_2} e^{-\frac{x}{\theta_2}} & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases} \quad (1)$$

donde θ_1 y θ_2 son dos parámetros positivos.

- a) **(5 puntos)** Probar que $\mathbf{E}(X) = p\theta_1 + (1-p)\theta_2$ y que $\mathbf{E}(X^2) = 2p\theta_1^2 + 2(1-p)\theta_2^2$.

Sugerencia: Identifique distribuciones conocidas para evitar cálculos.

- b) **(12 puntos)** Suponga que 100 clientes acceden al sistema. Se obtiene así una muestra de tiempos de servicios X_1, X_2, \dots, X_{100} *i.i.d.* con distribución correspondiente a la densidad definida en (1). Suponga además que $\theta_1 = 1$ y $\theta_2 = \frac{1}{2}$.

- i) Si $p = \frac{1}{3}$, estime la probabilidad de que el tiempo total de servicio, esto es $T = \sum_{i=1}^{100} X_i$, sea superior a 77.
- ii) Estime el menor valor de p para el cual se cumple $\mathbf{P}(T \leq 75) \leq \frac{1}{2}$.

- c) **(8 puntos)** Suponga ahora que 1000 clientes son asignados con igual probabilidad a cualquiera de los servidores. Esto es $X_1, X_2, \dots, X_{1000}$ son variables *i.i.d.* con distribución correspondiente a la densidad definida en (1) con $p = \frac{1}{2}$.

Sabiendo que $\theta_1 > \theta_2$ y que

$$\sum_{i=1}^{1000} X_i = 4000 \quad \text{y} \quad \sum_{i=1}^{1000} X_i^2 = 32080$$

estime los parámetros θ_1 y θ_2 por el método de los momentos.

- d) **(10 puntos)** Se dispone ahora de una muestra aleatoria (**no hay que verificar este supuesto**) de tiempos de servicios

0.19	0.05	1.34	0.98	0.57	0.11	0.37	1.35
------	------	------	------	------	------	------	------

- i) Calcule la función de distribución F_X de una variable aleatoria X con densidad definida en (1).
- ii) Verificar mediante una prueba de ajuste si los datos corresponden a la distribución calculada en la parte anterior con $\theta_1 = 1$, $\theta_2 = \frac{1}{2}$ y $p = 0.2$.

Ayuda: Puede ser de utilidad la siguiente tabla de valores

X_i	0.19	0.05	1.34	0.98	0.57	0.11	0.37	1.35
e^{-X_i}	0.827	0.951	0.262	0.375	0.565	0.896	0.691	0.259
e^{-2X_i}	0.684	0.905	0.069	0.141	0.320	0.802	0.477	0.067

Problema 2 (25 puntos)

Los siguientes datos corresponden a los pesos (medidos en kilogramos) de doce boxeadores en actividad del Palermo Boxing Club:

99.0	79.8	77.4	87.8	59.0	71.0	51.4	92.1	69.4	68.9	70.1	90.2
------	------	------	------	------	------	------	------	------	------	------	------

Ayuda: Pueden ser de utilidad los siguientes datos: $\bar{X}_n = 76.34$ y $\sigma_n = 13.51$.

- a) **(5 puntos)** ¿Es razonable suponer que los datos son aleatorios? (Realice una sola prueba de hipótesis)
- b) **(8 puntos)** ¿Es razonable suponer que los datos tienen distribución normal? (Realice una sola prueba de hipótesis)
- c) **(12 puntos)** Asumiendo que los datos tienen distribución normal $N(\mu, \sigma^2)$,
- i) ¿Es razonable suponer que $\mu = 75$?
- ii) ¿Es razonable suponer que $\sigma = 12$?

SOLUCIÓN

Problema 1

a) De la definición de valor esperado:

$$\mathbf{E}(X) = \int_{\mathbf{R}} x f_X(x) dx = p \int_0^{\infty} x \frac{1}{\theta_1} e^{-\frac{x}{\theta_1}} dx + (1-p) \int_0^{\infty} x \frac{1}{\theta_2} e^{-\frac{x}{\theta_2}} dx.$$

Notemos que la primera integral corresponde al valor esperado de una variable X_1 con distribución exponencial de parámetro $\frac{1}{\theta_1}$ y que la segunda integral corresponde al valor esperado de una variable X_2 con distribución exponencial de parámetro $\frac{1}{\theta_2}$, de manera que

$$\mathbf{E}(X) = p\mathbf{E}(X_1) + (1-p)\mathbf{E}(X_2) = p\theta_1 + (1-p)\theta_2.$$

Análogamente:

$$\mathbf{E}(X^2) = \int_{\mathbf{R}} x^2 f_X(x) dx = p \int_0^{\infty} x^2 \frac{1}{\theta_1} e^{-\frac{x}{\theta_1}} dx + (1-p) \int_0^{\infty} x^2 \frac{1}{\theta_2} e^{-\frac{x}{\theta_2}} dx = p\mathbf{E}(X_1^2) + (1-p)\mathbf{E}(X_2^2)$$

donde X_1 y X_2 son las variables definidas arriba. Ahora, si Y es una variable exponencial de parámetro λ , entonces $\mathbf{E}(Y^2) = 2 \frac{1}{\lambda^2}$. Por lo tanto:

$$\mathbf{E}(X^2) = 2p\theta_1^2 + 2(1-p)\theta_2^2.$$

b) Es fácil verificar que si X es una variable aleatoria con distribución correspondiente a la densidad definida en (1), con $\theta_1 = 1$ y $\theta_2 = \frac{1}{2}$, entonces

$$\mathbf{E}(X) = \frac{1}{2}(1+p) \quad \text{y} \quad \mathbf{Var}(X) = \mathbf{E}(X^2) - \mathbf{E}^2(X) = \frac{3}{2}p + \frac{1}{2} - \frac{1}{4}(1+p)^2. \quad (2)$$

i) Si $p = \frac{1}{3}$, resulta $\mu = \mathbf{E}(X) = \frac{2}{3}$ y $\sigma^2 = \mathbf{Var}(X) = \frac{5}{9}$. Para estimar $\mathbf{P}(T > 77)$ usamos el Teorema Central del Límite:

$$\begin{aligned} \mathbf{P}(T > 77) &= \mathbf{P}\left(\sum_{i=1}^{100} X_i > 77\right) = \mathbf{P}\left(\sqrt{100} \frac{(\bar{X}_{100} - \mu)}{\sigma} > 30 \frac{(\frac{77}{100} - \frac{2}{3})}{\sqrt{5}}\right) \\ &\simeq \mathbf{P}(N(0, 1) > 1.39) = 1 - \Phi(1.39) = 0.08227. \end{aligned}$$

ii) Usando (2) y el Teorema Central del Límite, resulta:

$$\begin{aligned} \mathbf{P}(T \leq 75) &= \mathbf{P}\left(\sqrt{100} \frac{[\bar{X}_{100} - \frac{1}{2}(1+p)]}{\sqrt{\frac{3}{2}p + \frac{1}{2} - \frac{1}{4}(1+p)^2}} \leq 10 \frac{[\frac{75}{100} - \frac{1}{2}(1+p)]}{\sqrt{\frac{3}{2}p + \frac{1}{2} - \frac{1}{4}(1+p)^2}}\right) \\ &\simeq \mathbf{P}\left(N(0, 1) \leq 10 \frac{[\frac{75}{100} - \frac{1}{2}(1+p)]}{\sqrt{\frac{3}{2}p + \frac{1}{2} - \frac{1}{4}(1+p)^2}}\right). \end{aligned}$$

De modo que $\mathbf{P}(T \leq 75) \leq \frac{1}{2}$ si y sólo si

$$\frac{75}{100} - \frac{1}{2}(1 + p) \leq 0,$$

esto es, si y sólo si $p \geq \frac{1}{2}$. Así que el menor valor de p para el cual se cumple la desigualdad es $p = \frac{1}{2}$.

- c) Para aplicar el método de los momentos consideramos las igualdades: $\bar{X} = \mathbf{E}(X)$ y $\overline{X^2} = \mathbf{E}(X^2)$. Usando los resultado de la parte a) con $p = \frac{1}{2}$ y los datos de la letra, queda el siguiente sistema de dos ecuaciones con dos incógnitas:

$$\frac{1}{2}\theta_1 + \frac{1}{2}\theta_2 = 4 \quad , \quad \theta_1^2 + \theta_2^2 = 32.080.$$

De la primera igualdad: $\theta_2 = 8 - \theta_1$. Llevando esto a la segunda igualdad se obtiene la siguiente ecuación cuadrática para θ_1 :

$$\theta_1^2 - 8\theta_1 + 15.96 = 0,$$

cuyas soluciones son 3.8 y 4.2. Es fácil ver que la solución $\theta_1 = 4.2$ corresponde a $\theta_2 = 3.8$ y viceversa. De manera que la estimación de parámetros por el método de los momentos, compatible con $\theta_1 > \theta_2$, es

$$\hat{\theta}_1 = 4.2 \quad \text{y} \quad \hat{\theta}_2 = 3.8.$$

d)

i)

$$F_X(t) = \int_{-\infty}^t f(x)dx = \begin{cases} 1 - p e^{-\frac{t}{\theta_1}} - (1-p) e^{-\frac{t}{\theta_2}} & \text{si } t > 0 \\ 0 & \text{si } t \leq 0 \end{cases}$$

- ii) Poniendo $\theta_1 = 1$, $\theta_2 = \frac{1}{2}$ y $p = 0.2$ en la expresión anterior, obtenemos la función de distribución:

$$F_0(t) = \begin{cases} 1 - 0.2 e^{-t} - 0.8 e^{-2t} & \text{si } t > 0 \\ 0 & \text{si } t \leq 0 \end{cases}$$

Para verificar si los datos corresponden a la función de distribución F_0 , implementamos la prueba de Kolmogorov-Smirnov. Para esto resulta de utilidad la tabla de valores dada en la Ayuda.

X_i^*	$\frac{i}{n}$	$F_0(X_i^*)$	$ \frac{i}{n} - F_0(X_i^*) $	$ \frac{i}{n} - F_0(X_{i+1}^*) $
0.05	0.125	0.0859	0.0391	0.0859
0.11	0.250	0.1789	0.0711	0.0539
0.19	0.375	0.2875	0.0875	0.0375
0.37	0.500	0.4802	0.0198	0.1052
0.57	0.625	0.6311	0.0061	0.1311
0.98	0.750	0.8123	0.0623	0.1873
1.34	0.825	0.8928	0.0178	0.1428
1.35	1	0.8944	0.1056	0.0194

De esta manera el estadístico del test es $D_n = 0.1873$ y de la tabla de Kolmogorov-Smirnov se obtiene $\alpha^* > 0.2$; por lo tanto aceptamos que la distribución de los datos es F_0 .

Problema 2

- a) Para estudiar si los datos pueden suponerse aleatorios realizamos el *Test de rachas de subidas y bajadas* o el *Test de Spearman*.

Test de Rachas

Recordamos que se definen las variables auxiliares U_i de la siguiente manera: $U_i = 1$ si $X_i \leq X_{i+1}$ y $U_i = 0$ en caso contrario.

X_i	U_i
99.0	
79.8	0
77.4	0
87.8	1
59.0	0
71.0	1
51.4	0
92.1	1
69.4	0
68.9	0
70.1	1
90.2	1

Hay 8 rachas, de manera que el estadístico del test es $R = 8$. Como $R = 8 > \frac{2(12)-1}{3} = 7.6667$, planteamos

H_0	H_1
X_1, X_2, \dots, X_n son <i>iid</i>	“hay muchas rachas”

Usando la tabla tenemos que el p -valor es $\alpha^* = 0.5547 > 0.1$. Conclusión: No se rechaza H_0 .

Test de rangos de Spearman

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	$R(X_i)$
51.4	7	1
59.0	5	2
68.9	10	3
69.4	9	4
70.1	11	5
71.0	6	6
77.4	3	7
79.8	2	8
87.8	4	9
90.2	12	10
92.1	8	11
99.0	1	12

Se obtiene $\sum_{i=1}^{12} (R(X_i) - i)^2 = 366$, y por lo tanto el estadístico del test resulta

$$r_s = 1 - 6 \frac{\sum_{i=1}^{12} (R(X_i) - i)^2}{12(12^2 - 1)} = -0.27972.$$

La tabla del test para $n = 12$ muestra que $\alpha^* > 0.10$. Por lo tanto la muestra pasa el test. Es razonable, entonces, suponer que la muestra es aleatoria.

b) Aplicamos las pruebas de normalidad:

Test de D'Agostino

El estadístico del test es

$$DA_n = \frac{\sum_{i=1}^n \left(i - \frac{n+1}{2}\right) X_i^*}{n^2 \sigma_n},$$

que en este caso da $DA_n = 0.282224$ y de la tabla se obtiene $\alpha^* > 0.20$. Por lo tanto la muestra pasa el test.

Test de Shapiro-Wilk

El estadístico del test es

$$W_n = \frac{\left(\sum_{i=1}^{\lfloor \frac{n}{2} \rfloor} a_i (X_{n-i+1}^* - X_i^*)\right)^2}{\sum_{i=1}^n (X_i - \bar{X}_n)^2}.$$

Orden inverso	Orden	a_i	$a_i(X_{n-i+1}^* - X_i^*)$
99.0	51.4	0.5475	26.061
92.1	59.0	0.3325	11.006
90.2	68.9	0.2347	4.999
87.8	69.4	0.1586	2.918
79.8	70.1	0.0922	0.894
77.4	71.0	0.0303	0.194

Por lo tanto $W_n = \frac{(46.07)^2}{2190.41} = 0.969$ y de la tabla se obtiene que el p -valor es $\alpha^* > 0.5$.

Conclusión: No se rechaza H_0 .

c) Asumimos aquí que los datos son normales.

- i) Construimos un intervalo de confianza al 90% para μ con σ desconocido (el intervalo es exacto, pues los datos son normales):

$$I = \left[\bar{X}_n - \frac{s_n}{\sqrt{n}} t_{\frac{\alpha}{2}}(n-1), \bar{X}_n + \frac{s_n}{\sqrt{n}} t_{\frac{\alpha}{2}}(n-1) \right]$$

Sabemos que

$$\bar{X}_n = 76.34, \quad t_{0.05}(11) = 1.796 \quad \text{y} \quad s_n = \sqrt{\frac{n}{n-1}} \sigma_n = 14.11$$

de manera que el intervalo de confianza queda

$$I = [69.017, 83.666].$$

Como el valor 75 cae dentro de ese intervalo concluimos que es razonable suponer $\mu = 75$.

De otra manera: Implementamos un test paramétrico para datos normales. Como $\bar{X}_n = 76.34$, consideramos las siguientes hipótesis

H₀	H₁
$\mu = 75$	$\mu > 75$

El estadístico del test es: $T = \sqrt{n} \left(\frac{\bar{X}_n - 75}{s_n} \right) = 0.329$ y la región crítica:

$$\mathcal{R}_\alpha = \{T \geq t_\alpha(n-1)\}.$$

Usando la tabla de la distribución *t*-Student se obtiene $0.25 < \alpha^* < 0.4$ y por lo tanto se acepta H_0 .

- ii) Construimos un intervalo de confianza al 90% para σ^2 con μ desconocido (el intervalo es exacto, pues los datos son normales):

$$I = \left[\frac{(n-1)}{\chi_{\frac{\alpha}{2}}^2(n-1)} s_n^2, \frac{(n-1)}{\chi_{1-\frac{\alpha}{2}}^2(n-1)} s_n^2 \right]$$

Sabemos que

$$s_n^2 = 199.11, \quad \chi_{0.05}^2(11) = 19.68 \quad \text{y} \quad \chi_{0.95}^2(11) = 4.57$$

de manera que el intervalo de confianza queda

$$I = [111.293, 479.265].$$

Como el valor $(12)^2 = 144$ cae dentro de ese intervalo concluimos que es razonable suponer $\sigma = 12$.

De otra manera: Implementamos un test paramétrico para datos normales. Como $s_n^2 = 199.11$, consideramos las siguientes hipótesis

\mathbf{H}_0	\mathbf{H}_1
$\sigma^2 = 144$	$\sigma^2 > 144$

El estadístico del test es: $E = \frac{(n-1)s_n^2}{12^2} = 15.210$ y la región crítica:

$$\mathcal{R}_\alpha = \{E \geq \chi_\alpha^2(n-1)\}.$$

Usando la tabla de la distribución χ^2 se obtiene $0.10 < \alpha^* < 0.50$ y por lo tanto se acepta H_0 .