

PROBABILIDAD Y ESTADISTICA 2001  
 SEGUNDO PARCIAL  
 PARTE B

**Índice General**

<b>1</b>	<b>TEST DE ALEATORIEDAD.</b>	<b>2</b>
1.1	Test de rachas de “subidas y bajadas” . . . . .	2
1.1.1	<b>Muestra 1</b> . . . . .	2
1.1.2	<b>Muestra 2</b> . . . . .	3
1.2	Test de correlación de rangos de Spearman. . . . .	4
1.2.1	<b>Muestra 1</b> . . . . .	4
1.2.2	<b>Muestra 2</b> . . . . .	5
<b>2</b>	<b>TEST DE COMPARACIÓN DE DOS MUESTRAS</b>	<b>7</b>
2.1	Test de Kolmogorov-Smirnov . . . . .	7
2.2	Tets de Mann -Whitney-Wilcoxon sobre “corrimientos”. . . . .	7
<b>3</b>	<b>TEST DE NORMALIDAD (ajuste).</b>	<b>8</b>
3.1	El Test de Normalidad de D’Agostino. . . . .	9
3.1.1	<b>Muestra 1</b> . . . . .	9
3.1.2	<b>Muestra 2</b> . . . . .	9
3.2	El Test de Normalidad de Shapiro - Wilks. . . . .	10
3.2.1	<b>Muestra 1</b> . . . . .	10
3.2.2	<b>Muestra 2</b> . . . . .	10
<b>4</b>	<b>TEST PARAMETRICOS</b>	<b>11</b>
4.1	Test paramétrico sobre “dispersión” . . . . .	11
4.2	Test de comparación de medias. . . . .	12
<b>5</b>	<b>Conclusión final</b>	<b>12</b>

## 1 TEST DE ALEATORIEDAD.

Vamos a verificar si la serie de observaciones (muestra) se puede considerar como aleatoria simple (m.a.s.) , es decir, si se puede aceptar que las observaciones proceden en forma **aleatoria e independiente** de una **misma distribución** (i.i.d.)

### 1.1 Test de rachas de “subidas y bajadas”

#### 1.1.1 Muestra 1

Se definen las variables

$$U_i = \begin{cases} 1 & \text{si } X_i \leq X_{i+1} \\ 0 & \text{caso contrario} \end{cases} \quad i = 1, 2, \dots, n - 1$$

y se cuentan las “rachas”

$X$	$U$	Rachas
70.1		
70.4	1	
75.8	1	1
67.5	0	2
68.4	1	
73.6	1	
76.9	1	3
75.7	0	
71.4	0	
70.3	0	4
72.1	1	5
69.8	0	6

Estadístico de prueba
$\mathbf{R}$ = número de total rachas = 6

Como

$$\mathbf{R} < \frac{2n - 1}{3} = \frac{2(12) - 1}{3} = 7.6667$$

planteamos

$\mathbf{H}_0$	$\mathbf{H}_1$
$X_1, \dots, X_n$ es una m.a.s.	“pocas rachas”

(“pocas rachas” = hay una tendencia de los datos a estar agrupados en orden creciente o en orden decreciente).

Usando la Tabla:

$n$	<b>R</b>		<b>R</b>	
	“pocas rachas”	$\alpha^*$	“muchas rachas”	$\alpha^*$
↓	↓			↓
↓				
12				
	1	.0000		
	2	.0000		
	3	.0005		
	4	.0082	11	.0113
	5	.0529	10	.0821
	<b>6</b>	<b>.1918</b>	9	.2720
→	7	.4453	8	.5547

Por lo tanto

$$\alpha^* = 0.1918 \geq 0.1$$

**Conclusión:** No rechazo  $H_0$

### 1.1.2 Muestra 2

Se definen las variables

$$U_i = \begin{cases} 1 & \text{si } Y_i \leq Y_{i+1} \\ 0 & \text{caso contrario} \end{cases} \quad i = 1, 2, \dots, n-1$$

y se cuentan las “rachas”

$Y$	$U$	Rachas
74.3		
74.1	0	1
75.4	1	2
67.4	0	3
69.3	1	
70.5	1	4
70.1	0	
69.9	0	
68.7	0	5
70.3	1	
70.7	1	
71.1	1	
74.4	1	6
70.2	0	7

**Estadístico de prueba**

**R = número de total rachas = 7**

Como

$$\mathbf{R} < \frac{2n-1}{3} = \frac{2(14)-1}{3} = 9$$

planteamos

$\mathbf{H}_0$	$\mathbf{H}_1$
$X_1, \dots, X_n$ es una m.a.s.	“pocas rachas”

(“pocas rachas” = hay una tendencia de los datos a estar agrupados en orden creciente o en orden decreciente).

Usando la Tabla:

$n$	$\mathbf{R}$		$\mathbf{R}$	
	“pocas rachas”	$\alpha^*$	“muchas rachas”	$\alpha^*$
↓	↓	↓	↓	↓
↓				
14	1	.0000		
	2	.0000		
	3	.0000		
	4	.0007	13	.0046
	5	.0079	12	.0391
	6	.0441	11	.1536
	7	.1534	10	.3722
→	8	.3633	9	.6367

Por lo tanto

$$\alpha^* = 0.1534 \geq 0.1$$

**Conclusión:** No rechazo  $\mathbf{H}_0$

## 1.2 Test de correlación de rangos de Spearman.

### 1.2.1 Muestra 1

<i>Datos ordenados</i> $X_i^*$	<i>Indice (dato original)</i> $i$	<i>Rango</i> $R(X_i)$
67,5	4	1
68,4	5	2
69,8	12	3
70,1	1	4
70,3	10	5
70,4	2	6
71,4	9	7
72,1	11	8
73,6	6	9
75,7	8	10
75,8	3	11
76,9	7	12

y como  $n = 12$  tenemos que:

Estadístico de prueba	
$\mathbf{R}_s = 1 - 6 \frac{\sum_{i=1}^{i=n} (R(X_i) - i)^2}{n(n^2 - 1)} = 1 - 6 \frac{264}{12((12)^2 - 1)} = 0,076923077$	

Como es estadístico de correlación de Spearman dió positivo planteamos:

$\mathbf{H}_0$	$\mathbf{H}_1$
$X_1, \dots, X_n$ es un m.a.s.	hay tendencia "creciente"

Usando la tabla tenemos que:

$n$	$\alpha^*$	0.1	0.05
↓	↑	↓	↓
⋮	⋮	⋮	⋮
12 →	$\mathbf{R}_s = 0,076923077$	0.406	0.503

por lo tanto

$$\alpha^* \geq 0.1 \text{ (p-valor)}$$

**Conclusión:** No se rechaza  $\mathbf{H}_0$ .

### 1.2.2 Muestra 2

<i>Datos ordenados</i> $Y_i^*$	<i>Indice (dato original)</i> $i$	<i>Rango</i> $R(Y_i)$
67.4	4	1
68.7	9	2
69.3	5	3
69.9	8	4
70.1	7	5
70.2	14	6
70.3	10	7
70.5	6	8
70.7	11	9
71.1	12	10
74.1	2	11
74.3	1	12
74.4	13	13
75.4	3	14

y como  $n = 14$  tenemos que:

Estadístico de prueba	
$\mathbf{R}_s = 1 - 6 \frac{\sum_{i=1}^{i=n} (R(Y_i) - i)^2}{n(n^2 - 1)} = 1 - 6 \frac{490}{14((14)^2 - 1)} = -0.076923077$	

Como es estadístico de correlación de Spearman dió negativo planteamos:

$\mathbf{H}_0$	$\mathbf{H}_1$
$X_1, \dots, X_n$ es un m.a.s.	hay tendencia "decreciente"

Usando la tabla tenemos que:

$n$	$\alpha^*$	<b>0.1</b>	<b>0.05</b>
↓	↑	↓	↓
⋮	⋮	⋮	⋮
14 →	$-\mathbf{R}_s = 0.076923077$	0.367	0.484

por lo tanto

$$\alpha^* \geq 0.1 \text{ (p-valor)}$$

**Conclusión:** No se rechaza  $\mathbf{H}_0$ .

## 2 TEST DE COMPARACIÓN DE DOS MUESTRAS

### 2.1 Test de Kolmogorov-Smirnov

Tenemos una muestra  $X_1, \dots, X_{12}$  iid con distribución  $F$  (continua) y una muestra  $Y_1, \dots, Y_{14}$  iid con distribución  $G$  (continua) e independientes entre si.

Planteamos

$$\begin{cases} (H_0) F = G \\ (H_1) F \neq G \end{cases}$$

Apliquemos el **test de Kolmogorov - Smirnov**

Estadístico de prueba	
$\mathbf{D} = \sup_{t \in R} \left\{ \left  F_n^X(t) - F_m^Y(t) \right  \right\}$	donde
$F_n^X(t) = (\text{cantidad de valores muestrales de } X \leq t)n$	
$F_m^Y(t) = (\text{cantidad de valores muestrales de } Y \leq t)m$	

(con  $n = 12$  y  $m = 14$ ) resultando

$$\mathbf{D} = \sup_{t \in R} \left\{ \left| F_m^Y(t) - F_n^X(t) \right| \right\} = 0,25$$

por lo tanto

$$mn\mathbf{D} = (12)(14)(0.25) = 42$$

resultando, de la tabla que

$\alpha^* > 0.2$
------------------

**Conclusión:** No se rechaza  $\mathbf{H}_0$ .

### 2.2 Tets de Mann -Whitney-Wilcoxon sobre “corrimientos”.

Sea  $X_1, \dots, X_{12}$  una m.a.s. con distribución  $F$  (continua y desconocida) e  $Y_1, \dots, Y_{14}$  una m.a.s. con distribución  $G$  (continua y desconocida) e inddendientes entre sí.

(Recordar que  $X$  es la muestra de **menor cantidad de datos**)

Estadístico de prueba
$\mathbf{T}_X = \text{“suma de rangos de } X \text{ en la muestra conjunta ordenada”}$

- El estadístico de prueba  $\mathbf{T}_X$  se determina de la siguiente manera:

– Se juntan **todos** los datos y se obtiene una muestra

$$Z_1, Z_2, \dots, Z_N \quad \text{donde } N = 12 + 14 = 26$$

– Se ordenan de menor a mayor (los valores que se repitan se escriben repetidos)

$$Z_1^* \leq Z_2^* \leq \dots \leq Z_N^*$$

- Se asignan rangos  $R(Z_i) =$  “lugar que ocupa  $Z_i$  en la muestra ordenada”
- **En este caso hay rangos “empataados” (datos iguales). Se reasignan los rangos, atribuyendole a cada empate el promedio de los rangos asignados inicialmente.**
- Se calcula  $\mathbf{T}_X =$  suma de rangos de los datos  $X_1, \dots, X_{12}$  (siendo  $\mathbf{T}_Y =$  suma de rangos de los datos  $Y_1, \dots, Y_{14}$ , se debe verificar que  $\mathbf{T}_X + \mathbf{T}_Y = \frac{N(N+1)}{2}$ )

Luego se obtiene

$$\mathbf{T}_X = 173$$

Como

$$\mathbf{T}_X \geq \frac{n(n+m+1)}{2} = \frac{12(12+14+1)}{2} = 162$$

Planteamos

$\mathbf{H}_0$	$\mathbf{H}_1$
$F = G$	$F(t) = G(t - \theta) \quad (\forall t \in R, \theta > 0)$

( es decir que 

$\mathbf{H}_0$	$\mathbf{H}_1$
$X \sim Y$	$X \sim Y + \theta \quad \text{con } \theta > 0 \quad (\text{“hay un corrimiento”})$

 )

Luego, usando la aproximación “normal” (incluida la “corrección de continuidad”) determinamos el p-valor:

$$z_R(\alpha^*) = \frac{\mathbf{T}_X - \frac{1}{2} - \frac{n(n+m+1)}{2}}{\sqrt{\frac{nm(n+m+1)}{12}}} = 0,848668425 \Leftrightarrow \alpha^* = 1 - \Phi(z_R(\alpha^*)) = 0,198032859$$

Conclusión: No se rechaza  $\mathbf{H}_0$

Coclusión primaria: No hay evidencia de diferencia significativa entre los niveles de contaminación de las ciudades

*NOTA: no se realizan tests no-parámétricos sobre “dispersión o escala”, pues las muestras son pequeñas; y en el curso vimos la versión “asintótica” de dichos tests.*

### 3 TEST DE NORMALIDAD (ajuste).

Vamos a aplicar el test de D’Agostino y el test de Shapiro - Wilks para determinar si los datos son normales (aunque los parámetros  $\mu$  y  $\sigma$  sean desconocidos)

Sea una m.a.s.  $X_1, \dots, X_n$  con distribución  $F$  (desconocida), planteamos

$\mathbf{H}_0$	$\mathbf{H}_1$
$F = \text{Normal}$	$F \neq \text{Normal}$



## 3.1 El Test de Normalidad de D'Agostino.

<b>Estadístico de prueba</b>	
$\mathbf{E} = \sum_{k=1}^{k=n} \frac{\left(k - \left(\frac{n+1}{2}\right)\right) X_{(k)}}{\sqrt{n^3 (n-1) s_n^2}}$	donde $X_{(1)} \leq \dots \leq X_{(n)}$ es la muestra ordenada

## 3.1.1 Muestra 1

Siendo  $n = 12$  y  $s_n^2 = \frac{\sum_{i=1}^{i=n} (X_i - \bar{X}_n)^2}{n-1} = 9,258787879$

se tiene que:

$$\mathbf{E} = 0,280325137$$

usando la tabla

<b>n</b>	<b><math>\alpha = 0.20</math></b>		<b><math>\alpha = 0.10</math></b>	
↓	↓	↓	↓	↓
12	<b><math>K_{1,\alpha}(n)</math></b>	<b><math>K_{2,\alpha}(n)</math></b>	<b><math>K_{1,\alpha}(n)</math></b>	<b><math>K_{2,\alpha}(n)</math></b>
	0.2653	0.2841	0.2598	0.2849

luego

$\alpha^* > 0.2$
------------------

**Conclusión:** No se rechaza  $\mathbf{H}_0$ .

## 3.1.2 Muestra 2

Siendo  $n = 12$  y  $s_n^2 = \frac{\sum_{i=1}^{i=n} (X_i - \bar{X}_n)^2}{n-1} = 5,819120879$

se tiene que:

$$\mathbf{E} = 0,271943628$$

usando la tabla

<b>n</b>	<b><math>\alpha = 0.20</math></b>		<b><math>\alpha = 0.10</math></b>	
↓	↓	↓	↓	↓
14	<b><math>K_{1,\alpha}(n)</math></b>	<b><math>K_{2,\alpha}(n)</math></b>	<b><math>K_{1,\alpha}(n)</math></b>	<b><math>K_{2,\alpha}(n)</math></b>
	0.2669	0.2846	0.2518	0.2853

luego

$\alpha^* > 0.2$
------------------

**Conclusión:** No se rechaza  $\mathbf{H}_0$ .

## 3.2 El Test de Normalidad de Shapiro - Wilks.

<b>Estadístico de prueba</b>	
$\mathbf{W} = \frac{(b_n)^2}{(n-1) s_n^2}$	
donde $b_n = a_n (X_{(n)} - X_{(1)}) + a_{n-1} (X_{(n-1)} - X_{(2)}) + \dots + a_k (X_{(n-k+1)} - X_{(k)})$ con $k = \left\lfloor \frac{n}{2} \right\rfloor$ y $X_{(1)} \leq \dots \leq X_{(n)}$ es la muestra ordenada (los coeficientes $a_i$ se obtienen de la tabla del test)	

## 3.2.1 Muestra 1

coeficientes $a_i$			
$X_{(12)} = 76,9$	$X_{(1)} = 67,5$	0,5475	
$X_{(11)} = 75,8$	$X_{(2)} = 68,4$	0,3325	
$X_{(10)} = 75,7$	$X_{(3)} = 69,8$	0,2347	$\Rightarrow$
$X_{(9)} = 73,6$	$X_{(4)} = 70,1$	0,1586	$b_n = 9,74309$
$X_{(8)} = 72,1$	$X_{(5)} = 70,3$	0,0922	
$X_{(7)} = 71,4$	$X_{(6)} = 70,4$	0,0303	

por lo tanto

$$\mathbf{W} = 0,932065878$$

usando la tabla

<b>n</b>	<b><math>\alpha = 0.1</math></b>	<b><math>\alpha = 0.5</math></b>
↓	↓	↓
12	0.883	0.943

luego

$0.1 < \alpha^* < 0.5$
------------------------

**Conclusión:** No se rechaza  $\mathbf{H}_0$ .

## 3.2.2 Muestra 2

coeficientes $a_i$			
$X_{(14)} = 75,4$	$X_{(1)} = 67,4$	0,5251	
$X_{(13)} = 74,4$	$X_{(2)} = 68,7$	0,3318	
$X_{(12)} = 74,3$	$X_{(3)} = 69,3$	0,246	$\Rightarrow$
$X_{(11)} = 74,1$	$X_{(4)} = 69,9$	0,1802	$b_n = 8,24405$
$X_{(10)} = 71,1$	$X_{(5)} = 70,1$	0,124	
$X_{(9)} = 70,7$	$X_{(6)} = 70,2$	0,0727	
$X_{(8)} = 70,5$	$X_{(7)} = 70,3$	0,024	

por lo tanto

$$\mathbf{W} = 0,898422259$$

usando la tabla

$\mathbf{n}$	$\alpha = 0.1$	$\alpha = 0.5$
↓	↓	↓
14	0.895	0.947

luego

$0.1 < \alpha^* < 0.5$
------------------------

**Conclusión:** No se rechaza  $\mathbf{H}_0$ .

## 4 TEST PARAMETRICOS

Asumiendo la normalidad de los datos, de acuerdo con la parte anterior, realizamos:

### 4.1 Test paramétrico sobre “dispersión”

Sea  $X_1, X_2, \dots, X_n$  una m.a.s con distribución  $N(\mu_X, \sigma_X^2)$  e  $Y_1, Y_2, \dots, Y_m$  una m.a.s con distribución  $N(\mu_Y, \sigma_Y^2)$  e independientes entre si, donde  $\sigma_X^2 = \mathbf{Var}(X)$  y  $\sigma_Y^2 = \mathbf{Var}(Y)$  son desconocidas

Calculamos las estimaciones de las varianzas

$$s_n^2(X) = 9,258787879 \quad \text{y} \quad s_m^2(Y) = 5,819120879$$

Planteamos

$\mathbf{H}_0$	$\mathbf{H}_1$	Estadístico de prueba	Región crítica
$\sigma_X^2 = \sigma_Y^2$	$\sigma_X^2 > \sigma_Y^2$	$\mathbf{F} = \frac{s_n^2(X)}{s_m^2(Y)}$	$\mathbf{F} \geq f_\alpha(n-1, m-1)$

resultando

$$\mathbf{F} = \frac{s_n^2(X)}{s_m^2(Y)} = \frac{9,258787879}{5,819120879} = 1.591097362$$

y usando la Tabla con  $\alpha = 0.1$

$n$	→	10	12
$m$		↓	↓
		↓	↓
13	→	2, 14	2, 1

por lo tanto  $\alpha^* > 0.1$

**Conclusión:** No Rechazamos  $\mathbf{H}_0$

## 4.2 Test de comparación de medias.

Sea  $X_1, X_2, \dots, X_n$  una m.a.s con distribución  $N(\mu_X, \sigma_X^2)$  e  $Y_1, Y_2, \dots, Y_m$  una m.a.s con distribución  $N(\mu_Y, \sigma_Y^2)$  e independientes entre si,, donde  $\sigma_X^2 = \mathbf{Var}(X)$  y  $\sigma_Y^2 = \mathbf{Var}(Y)$  son desconocidas pero iguales

$\mathbf{H}_0$	$\mathbf{H}_1$	Estadístico de prueba	Región crítica
$\mu_X = \mu_Y$	$\mu_X \neq \mu_Y$	$\mathbf{T} = \frac{\bar{X}_n - \bar{Y}_m}{s_p \sqrt{\frac{1}{n} + \frac{1}{m}}}$	$ \mathbf{T}  \geq t_{\frac{\alpha}{2}}(n + m - 2)$

calculando

$$\begin{aligned} \bar{X}_n &= 71,83333333 & \text{y} & & \bar{Y}_m &= 71,17142857 \\ s_n^2(X) &= 9,258787879 & \text{y} & & s_m^2(Y) &= 5,819120879 \end{aligned}$$

tenemos que

$$s_p^2 = \frac{(n-1)s_n^2(X) + (m-1)s_m^2(X)}{n+m-2} = 7.395634921$$

y por lo tanto

$$\mathbf{T} = \frac{\bar{X}_n - \bar{Y}_m}{s_p \sqrt{\frac{1}{n} + \frac{1}{m}}} = \frac{71.83333333 - 71.17142857}{\sqrt{(7.395634921) \left( \frac{1}{12} + \frac{1}{14} \right)}} = 0.61869$$

usando la tabla

$$\begin{array}{cccc} \alpha \longrightarrow & 0.4 & \frac{\alpha^*}{2} & 0.25 \\ & & \uparrow & \\ & n \downarrow & & \\ & 24 & 0.256 & \mathbf{T} = 0.61869 \quad 0,685 \end{array}$$

por lo tanto el p-valor  $\alpha^*$  cumple que

$$0.25 < \frac{\alpha^*}{2} < 0.4 \Leftrightarrow \boxed{0.5 < \alpha^* < 0.8}$$

**Conclusión:** No se rechaza  $\mathbf{H}_0$ .

## 5 Conclusión final

Ambas muestras son normales con la misma media y la misma varianza.

No hay diferencia significativa entre los niveles de contaminación de ambas ciudades.