

NOTAS DE CLASE :

**Introducción a la Estadística  
con Apoyo Computacional**

Felipe Osorio y Ronny Vallejos

DEPARTAMENTO DE MATEMÁTICA, UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA



## Índice general

Capítulo 1. Estadística Descriptiva	1
1.1. Preliminares: Sumas y Productos	1
1.2. Estadísticas de Resumen	4
1.3. Covarianza y correlación	26
1.4. Estadísticas descriptivas multivariadas	29
1.5. Regresión lineal simple	33
Bibliografía	39



## Estadística Descriptiva

### 1.1. Preliminares: Sumas y Productos

En esta sección se introduce una notación que tiene por objetivo escribir de forma compacta sumas y productos de secuencias de números  $a_1, a_2, \dots$ , donde  $a_i \in \mathbb{R}$ , para todo  $i$ .

DEFINICIÓN 1.1. Considere una secuencia de números  $a_1, a_2, \dots$ . Se define la *sumatoria* de esta secuencia, como:

$$\sum_{i=1}^n a_i = a_1 + a_2 + \dots + a_n, \quad (1.1)$$

donde  $i$  denota el índice de la sumatoria, mientras  $a_i$  representa un elemento genérico. En este caso,  $n$  indica la cantidad de elementos que se están sumando.

Es posible apreciar que la suma en (1.1) puede ser escrita de manera análoga como

$$\sum_{1 \leq i \leq n} a_i = a_1 + a_2 + \dots + a_n. \quad (1.2)$$

Debemos notar que, si  $n = 0$  el valor de la sumatoria se define como cero.

OBSERVACIÓN 1.2. A partir de la Ecuación en (1.2) podemos introducir una notación mucho más general. En efecto, sea  $R$  un conjunto de índices. Así, basta considerar el conjunto  $R = \{1, 2, \dots, n\}$ , para re-escribir la suma en (1.2) como:

$$\sum_{i \in R} a_i = a_1 + \dots + a_n. \quad (1.3)$$

OBSERVACIÓN 1.3. Aunque frecuentemente la notación dada en la Ecuación (1.3) es utilizada para sumas finitas, esta puede ser adaptada con facilidad para sumas infinitas. Por ejemplo,

$$\sum_{i=1}^{\infty} a_i = \sum_{i \geq 1} a_i = a_1 + a_2 + \dots$$

Más formalmente, debemos escribir

$$\sum_{i=1}^{\infty} a_i = \lim_{n \rightarrow \infty} \sum_{i=1}^n a_i.$$

RESULTADO 1.4 (Regla constante). *Sea  $a$  un número real. De este modo,*

$$\sum_{i=1}^n a = a + \dots + a = na.$$

En general, para  $r < n$  tenemos

$$\sum_{i=r}^n a = (n - r + 1)a, \quad a \in \mathbb{R}.$$

RESULTADO 1.5. Considere la secuencia  $x_1, \dots, x_n$  y sea  $a$  una constante. Entonces,

$$\sum_{i=1}^n a x_i = a x_1 + \dots + a x_n = a(x_1 + \dots + x_n) = a \sum_{i=1}^n x_i.$$

En general, sean  $x_1, \dots, x_n$  y  $y_1, \dots, y_n$  dos secuencias de números y  $a, b \in \mathbb{R}$ . Entonces,

$$\sum_{i=1}^n (a x_i + b y_i) = a \sum_{i=1}^n x_i + b \sum_{i=1}^n y_i.$$

Note también que las sumatorias pueden ser *descompuestas* en varias sumas. En efecto, para una secuencia de números  $a_1, \dots, a_n$ . Tenemos que

$$\sum_{i=1}^n a_i = \sum_{i=1}^k a_i + \sum_{i=k+1}^n a_i, \quad k < n.$$

En general, sea  $R = R_1 \cup R_2$ , tal que  $R_1 \cap R_2 = \emptyset$ . Entonces,

$$\sum_{i \in R} a_i = \sum_{i \in R_1} a_i + \sum_{i \in R_2} a_i.$$

EJEMPLO 1.6 (Propiedad telescópica). Considere  $a_0, a_1, \dots, a_n$  una secuencia de números reales, y considere

$$\begin{aligned} \sum_{i=1}^n (a_i - a_{i-1}) &= (a_1 - a_0) + (a_2 - a_1) + \dots + (a_{n-1} - a_{n-2}) + (a_n - a_{n-1}) \\ &= -a_0 + (a_1 - a_1) + \dots + (a_{n-1} - a_{n-1}) + a_n \\ &= a_n - a_0. \end{aligned}$$

EJEMPLO 1.7 (Suma de una progresión geométrica). Asuma que  $x \neq 1$  y  $n \geq 0$ . Entonces,

$$\begin{aligned} a + ax + \dots + ax^n &= \sum_{j=0}^n ax^j \\ &= a + \sum_{j=1}^n ax^j = a + (ax + \dots + ax^n) = a + x(a + \dots + ax^{n-1}) \end{aligned} \quad (1.4)$$

$$= a + x \sum_{j=1}^n ax^{j-1} = a + x \sum_{j=0}^{n-1} ax^j \quad (1.5)$$

$$= a + x \sum_{j=0}^n ax^j - ax^{n+1}. \quad (1.6)$$

Tomando la primera y última relaciones, sigue que

$$\sum_{j=0}^n ax^j = a + x \sum_{j=0}^n ax^j - ax^{n+1},$$

es decir,

$$(1-x) \sum_{j=0}^n ax^{j-1} = a - ax^{n+1}.$$

De este modo, obtenemos finalmente

$$\sum_{j=0}^n ax^j = a \left( \frac{1-x^{n+1}}{1-x} \right).$$

En este ejemplo se han utilizado diversos elementos que permiten notar algunas de las propiedades de las sumatorias. En efecto, en Ecuación (1.4) se utilizó una muy particular versión del Resultado 1.5. Mientras que en (1.5) y (1.6) se realizó un cambio en el índice de la suma y reorganizó los términos (es decir el dominio sobre el que opera la suma) para obtener el resultado deseado.

Las siguientes son igualdades que **no** **satisface** la suma:

- Sean  $a_1, \dots, a_n$  y  $b_1, \dots, b_n$  dos secuencias de números reales. Entonces

$$\sum_{i=1}^n a_i b_i \neq \left( \sum_{i=1}^n a_i \right) \left( \sum_{i=1}^n b_i \right). \quad (1.7)$$

En efecto, basta notar que la cantidad de términos involucrados en cada uno de los lados de la ecuación anterior es diferente.

- Un caso particular del anterior es

$$\sum_{i=1}^n x_i^2 \neq \left( \sum_{i=1}^n x_i \right)^2.$$

- En general, si  $f : \mathbb{R} \rightarrow \mathbb{R}$  es una función no lineal. Entonces

$$\sum_{i=1}^n f(x_i) \neq f \left( \sum_{i=1}^n x_i \right).$$

En ocasiones disponemos de secuencias números indexados mediante dos (o más) índices, es decir  $\{a_{ij}\}$  (las matrices son un caso habitual de esta situación). Por ejemplo, si consideramos  $\mathbf{A} = (a_{ij}) \in \mathbb{R}^{m \times n}$  (es decir  $i = 1, \dots, m, j = 1, \dots, n$ ) y suponga que deseamos sumar todos los elementos de la matriz  $\mathbf{A}$ . Es decir,

$$\sum_{i=1}^m \sum_{j=1}^n a_{ij} = a_{11} + \dots + a_{1n} + \dots + a_{m1} + \dots + a_{mn}.$$

Notamos fácilmente que podemos intercambiar el orden de las sumas. En efecto,

$$\sum_{i=1}^m \sum_{j=1}^n a_{ij} = \sum_{j=1}^n \sum_{i=1}^m a_{ij}$$

OBSERVACIÓN 1.8. Se debe resaltar que la operación de intercambiar el orden de las sumas **no** siempre es válido para series infinitas.

Retomando el resultado de la Ecuación (1.7), es válido considerar

$$\left( \sum_{i=1}^m a_i \right) \left( \sum_{j=1}^n b_j \right) = \sum_{i=1}^m \sum_{j=1}^n a_i b_j, \quad (1.8)$$

asimismo

$$\left(\sum_{i=1}^n x_i\right)^2 = \left(\sum_{i=1}^n x_i\right)\left(\sum_{j=1}^n x_j\right) = \sum_{i=1}^n \sum_{j=1}^n x_i x_j.$$

Para comprender mejor la Ecuación (1.8) considere un caso especial

$$\begin{aligned} \left(\sum_{i=1}^2 a_i\right)\left(\sum_{j=1}^3 b_j\right) &= (a_1 + a_2)(b_1 + b_2 + b_3) \\ &= (a_1 b_1 + a_1 b_2 + a_1 b_3) + (a_2 b_1 + a_2 b_2 + a_2 b_3) \\ &= \sum_{i=1}^2 \left(\sum_{j=1}^3 a_i b_j\right). \end{aligned}$$

Otros ejemplos de sumas útiles (que pueden ser probadas usando inducción) son:

- $\sum_{k=1}^n k = 1 + 2 + \dots + n = \frac{n(n+1)}{2}.$
- $\sum_{k=1}^n k^2 = 1^2 + 2^2 + \dots + n^2 = \frac{n(n+1)(2n+1)}{6}.$

Existe una notación análoga para productos. En efecto, considere la siguiente definición

DEFINICIÓN 1.9. Sea  $a_1, a_2, \dots$  una secuencia de números. Se define la *productoria* de esta secuencia, como:

$$\prod_{i=1}^n a_i = a_1 a_2 \cdots a_n. \quad (1.9)$$

En general, podemos escribir

$$\prod_{i \in R} a_i,$$

donde  $R$  representa un conjunto de índices. Note que si no existe algún entero  $i \in R$ , el producto se define con el valor uno.

EJEMPLO 1.10 (factorial de un número). Un ejemplo del uso de productorios es:

$$n(n-1)(n-2)\cdots 1 = \prod_{j=0}^{n-1} (n-j) = \prod_{j=1}^n j = n!$$

que se denomina  $n$  factorial. Recuerde que  $0!$  por definición es 1.

## 1.2. Estadísticas de Resumen

**1.2.1. Medidas de Posición.** Se introduce una serie de medidas que permiten resumir un gran volumen de información y cuantifican el valor central de un conjunto de datos.

DEFINICIÓN 1.11 (Media muestral o promedio). Sea  $x_1, \dots, x_n$  valores muestrales. Se define el *promedio* o *media muestral* como:

$$\bar{x} = \frac{1}{n}(x_1 + \dots + x_n) = \frac{1}{n} \sum_{i=1}^n x_i. \quad (1.10)$$



Suponga que la observación  $i$ -ésima, digamos  $x_i$ , se repite  $n_i$  veces. Entonces tenemos que

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n n_i x_i = \sum_{i=1}^n f_i x_i, \quad (1.11)$$

donde  $f_i = n_i/n$  es la frecuencia relativa. Considere “pesos” o ponderaciones  $\omega_1, \dots, \omega_n$  asociados a las observaciones  $x_1, \dots, x_n$ . En este caso tenemos,

$$\bar{x} = \frac{1}{\sum_{j=1}^n \omega_j} \sum_{i=1}^n \omega_i x_i, \quad (1.12)$$

si consideramos la proporción

$$p_i = \frac{\omega_i}{\sum_{j=1}^n \omega_j}, \quad i = 1, \dots, n,$$

entonces podemos re-escribir (1.12) como

$$\bar{x} = \sum_{i=1}^n p_i x_i.$$

Note que el promedio en Ecuación (1.11) es un caso particular donde  $\sum_i f_i = 1$ .

EJEMPLO 1.12. Considere el conjunto de datos  $\{1, 2, 2, 2, 3, 3, 8\}$ . Tenemos  $n = 7$ , y

$$\sum_{i=1}^7 x_i = 1 + 2 \cdot 3 + 2 \cdot 3 + 8 = 21,$$

así  $\bar{x} = 21/7 = 3$ . Note también que el gráfico de *tallo y hoja*, adopta la forma:

1	*		
2	* * *		
3	* *		
4			
5			
6			
7			
8	*		

EJEMPLO 1.13 (Datos de accidentes). Suponga el siguiente conjunto de datos:

Número de accidentes ( $x_i$ )	Frecuencia ( $n_i$ )	$n_i x_i$
0	55	0
1	14	14
2	5	10
3	2	6
4	0	0
Total	76	30

De este modo,  $\bar{x} = 30/76 = 0.395$  es el número promedio de accidentes.

Considere que el conjunto de observaciones  $x_1, \dots, x_n$  es ordenado de menor a mayor como:

$$x_{(1)}, x_{(2)}, \dots, x_{(n)},$$

tal que  $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$ , donde  $x_{(k)}$  se denomina la  $k$ -ésima estadística de orden.

DEFINICIÓN 1.14 (Mediana). Sean  $x_{(1)}, \dots, x_{(n)}$  observaciones ordenadas. Si  $n$  es impar, entonces la *mediana* se define como la observación central, es decir

$$\text{me} = x_{((n+1)/2)},$$

en el caso que  $n$  sea par, entonces

$$\text{me} = \frac{1}{2} \left( x_{(n/2)} + x_{(n/2+1)} \right).$$

OBSERVACIÓN 1.15. En ocasiones escribiremos  $\text{me}(\mathbf{x})$  para indicar cual es el conjunto de datos sobre el que se calcula la mediana.

DEFINICIÓN 1.16 (Moda). La *moda* o *valor modal* es el valor observado con la más alta ocurrencia.

OBSERVACIÓN 1.17. Respecto de las medidas de tendencia central introducidas anteriormente podemos apreciar que:

- El promedio puede verse fuertemente afectado por *datos atípicos*.
- La mediana “divide” el conjunto de datos en dos, es decir, el 50% de los datos están por debajo de la mediana, mientras que el 50% se encuentran por sobre este valor.
- En general, la moda no es única y puede no existir.
- Es interesante notar diferencia entre la complejidad de cálculo del promedio versus la mediana.

OBSERVACIÓN 1.18 (Otras medidas de tendencia central). Sea  $f(x)$  cualquier función de números reales. Entonces podemos definir

$$\bar{f} = \frac{1}{n} \sum_{i=1}^n f(x_i) = \frac{1}{n} \left( f(x_1) + \dots + f(x_n) \right).$$

Los siguientes casos particulares son de interés:

- (a) *Média cuadrática*. Considere  $f(x) = x^2$ . Entonces se define la media cuadrática,  $Q$  como:

$$Q = \frac{1}{n} \sum_{i=1}^n x_i^2.$$

- (b) *Média armónica*. Sea  $f(x) = 1/x$ . Entonces, decimos que  $H$  es la media armónica si

$$\frac{1}{H} = \frac{1}{n} \left( \frac{1}{x_1} + \frac{1}{x_2} + \dots + \frac{1}{x_n} \right) = \frac{1}{n} \sum_{i=1}^n \frac{1}{x_i}.$$

Es decir,  $H$  es el inverso de la media aritmética de los inversos de los valores observados. De donde sigue que,

$$H = \frac{n}{\sum_{i=1}^n 1/x_i}.$$

(c) *Médiva geométrica*. Considere  $f(x) = \log x$ . Entonces la media geométrica  $G$  es definida por la fórmula

$$\log G = \frac{1}{n} (\log x_1 + \cdots + \log x_n) = \frac{1}{n} \sum_{i=1}^n \log x_i.$$

Es decir,

$$G = \left( \prod_{i=1}^n x_i \right)^{1/n}.$$

**1.2.2. Medidas de Dispersión.** Considere los conjuntos de datos:

$$D_1 = \{10, 20, 30\}, \quad D_2 = \{5, 5, 20, 35, 35\}, \quad D_3 = \{20, 20, 20\}.$$

Tenemos los gráficos de tallo-y-hoja:

Datos $D_1$ :	Datos $D_2$ :	Datos $D_3$ :
5	5	5
10	10	10
15	15	15
20	20	20
25	25	25
30	30	30
35	35	35

Sea  $\bar{x}_j$  y  $me_j$  el promedio y la mediana asociada al conjunto de datos  $D_j$  ( $j = 1, 2, 3$ ). Entonces,

$$\begin{aligned} \bar{x}_1 &= \frac{1}{3}(10 + 20 + 30) = \frac{60}{3} = 20, \\ \bar{x}_2 &= \frac{1}{5}(2 \cdot 5 + 20 + 2 \cdot 35) = \frac{100}{5} = 20, \\ \bar{x}_3 &= \frac{3 \cdot 20}{3} = 20. \end{aligned}$$

Además,  $me_j = 20$  para todo  $j$ . Es decir, tenemos tres configuraciones de datos con valores centrales idénticos.

Esto motiva la introducción de medidas que permitan caracterizar la variabilidad o dispersión de un conjunto de observaciones. Algunas medidas simples corresponden a los *cuartiles*. En efecto, sea  $Q_1$  y  $Q_3$  las medianas de la mitad inferior y superior de los datos, respectivamente. Entonces, esto lleva a definir la siguiente medida de dispersión:

$$IQR = Q_3 - Q_1,$$

el que es conocido como *rango intercuartílico*. Es interesante notar que algunos software estadísticos (por ejemplo, R/S-Plus, Stata, entre otros) reportan:

$$\min\{x_i\}_{i=1}^n, Q_1, me, Q_3, \max\{x_i\}_{i=1}^n.$$

Así, también podemos considerar el *rango* de la muestra como

$$R = \max\{x_i\}_{i=1}^n - \min\{x_i\}_{i=1}^n = x_{(n)} - x_{(1)}.$$

Por otro lado, se ha sugerido utilizar subdivisiones más finas que los cuartiles. Por ejemplo, considere subdividir los datos ordenados  $x_{(1)}, \dots, x_{(n)}$  en secciones de

100%, llamados *percentiles*. Precisamente, si disponemos de los datos ordenados  $x_{(1)}, \dots, x_{(n)}$ , entonces el percentil de orden  $j$  ( $1 \leq j \leq 100$ ) está dado por:

$$P_j = x_{(j(n+1)/100)}. \quad (1.13)$$

Debemos notar además que, el primer cuartil  $Q_1$  corresponde al percentil 25°, mientras que la mediana (o 2° cuartil,  $Q_2$ ) representa el percentil 50° y  $Q_3$  corresponde al percentil 75°.

EJERCICIO 1.19. Considere el conjunto de datos  $\mathbf{x} = (4, 7, 18, 1, 7, 13, 2)^\top$  y suponga que deseamos calcular  $P_{75}$  y rango intercuartílico  $IQR$ .

Primeramente es necesario ordenar el conjunto de datos:

$$(x_{(1)}, x_{(2)}, x_{(3)}, x_{(4)}, x_{(5)}, x_{(6)}, x_{(7)})^\top = (1, 2, 4, 7, 7, 13, 18)^\top.$$

Disponemos de  $n = 7$  datos, luego para obtener el 1er y 3er cuartiles podemos usar la fórmula del percentil en (1.13). En efecto,

$$\begin{aligned} Q_1 = P_{25} &= x_{(25 \cdot (7+1)/100)} = x_{(1.8/4)} = x_{(2)} = 2, \\ Q_3 = P_{75} &= x_{(75 \cdot (7+1)/100)} = x_{(3.8/4)} = x_{(6)} = 13. \end{aligned}$$

De este modo,  $IQR = Q_3 - Q_1 = 13 - 2 = 11$ .

DEFINICIÓN 1.20 (Varianza muestral). Considere  $x_1, \dots, x_n$  valores observados, se define su *varianza muestral* como:

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2. \quad (1.14)$$

Note que  $s^2$  corresponde a un “promedio” de los desvios al cuadrado con relación a la media. También se suele anotar  $s_x^2$  o bien  $\text{var}(x)$ .

Aunque en ocasiones es recomendable dividir la suma de cuadrados en (1.14) por  $n$ . En el capítulo de inferencia veremos la razón de utilizar  $n - 1$ .

OBSERVACIÓN 1.21.  $s = \sqrt{s^2}$  se denomina desviación estándar.

Basados en Ecuación (1.14) podemos definir otras medidas de dispersión:

- *Desviación absoluta en torno de la media*

$$\frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}|. \quad (1.15)$$

- *Desviación absoluta en torno de la mediana*

$$\frac{1}{n} \sum_{i=1}^n |x_i - \text{me}|. \quad (1.16)$$

OBSERVACIÓN 1.22. En general podemos considerar, por ejemplo:

$$g(T) = \frac{1}{n} \sum_{i=1}^n h(x_i - T(\mathbf{x})),$$

donde  $T(\mathbf{x})$  es alguna estadística de la muestra  $\mathbf{x} = (x_1, \dots, x_n)^\top$ . Note que si  $T(\mathbf{x}) = \bar{x}$  y  $h(z) = z^2$ , obtenemos la varianza. Mientras que para  $T(\mathbf{x}) = \text{me}$  y  $h(z) = |z|$  obtenemos (1.16).

De este modo, podemos definir el  $r$ -ésimo momento centrado en torno de  $a$ , como

$$M_r(a) = \frac{1}{n} \sum_{i=1}^n (x_i - a)^r. \quad (1.17)$$

PROPIEDAD 1.23. A continuación se describen una serie de propiedades del promedio y la varianza de un conjunto de datos observados.

(a)  $\sum_{i=1}^n (x_i - \bar{x}) = 0$ . En efecto,

$$\sum_{i=1}^n (x_i - \bar{x}) = \sum_{i=1}^n x_i - \sum_{i=1}^n \bar{x} = \sum_{i=1}^n x_i - n\bar{x} = n\bar{x} - n\bar{x} = 0.$$

(b) (Fórmula de Köning)

$$\begin{aligned} \sum_{i=1}^n (x_i - \bar{x})^2 &= \sum_{i=1}^n (x_i^2 - 2x_i\bar{x} + \bar{x}^2) = \sum_{i=1}^n x_i^2 - 2\bar{x} \sum_{i=1}^n x_i + n\bar{x}^2 \\ &= \sum_{i=1}^n x_i^2 - n\bar{x}^2 = \sum_{i=1}^n x_i^2 - \frac{1}{n} \left( \sum_{i=1}^n x_i \right)^2 \end{aligned} \quad (1.18)$$

(c)  $\bar{x}$  es el valor que minimiza la función  $S(a) = \sum_{i=1}^n (x_i - a)^2$ . En efecto, note que

$$\frac{d}{da} S(a) = \sum_{i=1}^n \frac{d}{da} (x_i - a)^2 = -2 \sum_{i=1}^n (x_i - a),$$

resolviendo la condición de primer orden, tenemos

$$\sum_{i=1}^n (x_i - \hat{a}) = 0,$$

desde donde sigue que  $\hat{a} = \bar{x}$ . Además

$$\frac{d^2}{da^2} S(a) = -2 \sum_{i=1}^n \frac{d}{da} (x_i - a) = 2n,$$

y como la segunda derivada es positiva (para cualquier valor de  $n$ ), obtenemos que  $\bar{x}$  es máximo global.

Una manera alternativa para probar este resultado puede ser obtenida mediante notar que

$$\begin{aligned} S(a) &= \sum_{i=1}^n (x_i - a)^2 = \sum_{i=1}^n \{(x_i - \bar{x}) + (\bar{x} - a)\}^2 \\ &= \sum_{i=1}^n (x_i - \bar{x})^2 + 2(\bar{x} - a) \sum_{i=1}^n (x_i - \bar{x}) + \sum_{i=1}^n (\bar{x} - a)^2. \end{aligned}$$

Por la propiedad en (a) y notando que el término  $(\bar{x} - a)^2$  es constante para la suma. Obtenemos

$$S(a) = \sum_{i=1}^n (x_i - \bar{x})^2 + n(\bar{x} - a)^2,$$

y de este modo, resulta evidente que  $S(a)$  alcanza su mínimo para  $\hat{a} = \bar{x}$ .

(d) Sea  $x_1, \dots, x_n$  y considere la transformación

$$y_i = ax_i + b.$$

Entonces

$$\bar{y} = a\bar{x} + b, \quad s_y^2 = a^2 s_x^2.$$

En efecto,

$$\begin{aligned} \bar{y} &= \frac{1}{n} \sum_{i=1}^n y_i = \frac{1}{n} \sum_{i=1}^n (ax_i + b) = \frac{1}{n} \left( a \sum_{i=1}^n x_i + b \right) \\ &= a \left( \frac{1}{n} \sum_{i=1}^n x_i \right) + b = a\bar{x} + b. \end{aligned}$$

Mientras que

$$s_y^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2,$$

como  $y_i - \bar{y} = ax_i + b - (a\bar{x} + b) = a(x_i - \bar{x})$ , sigue que

$$\begin{aligned} s_y^2 &= \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2 = \frac{1}{n-1} \sum_{i=1}^n \{a(x_i - \bar{x})\}^2 \\ &= a^2 \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = a^2 s_x^2. \end{aligned}$$

En particular, si (que corresponde a una *estandarización* del conjunto de datos  $x_1, \dots, x_n$ )

$$z_i = \frac{x_i - \bar{x}}{s}, \quad i = 1, \dots, n.$$

Entonces  $\bar{z} = 0$  y  $s_z^2 = 1$ . En efecto, en la Propiedad 1.23 (d) basta hacer  $a = 1/s$  y  $b = \bar{x}/s$ .

(e) Sea  $x_1, \dots, x_n$  un conjunto de  $n$  observaciones. Considere aplicar la transformación

$$y_i = g(x_i), \quad i = 1, \dots, n,$$

con  $g(\cdot)$  función dos veces diferenciable y suponga que utilizamos una aproximación de Taylor de primer orden en torno del promedio. Es decir,

$$g(x_i) \approx g(\bar{x}) + g'(\bar{x})(x_i - \bar{x}).$$

De este modo,  $\bar{y} = \bar{g}(\mathbf{x})$ , y

$$\begin{aligned} \bar{g}(\mathbf{x}) &= \frac{1}{n} \sum_{i=1}^n g(x_i) \approx \frac{1}{n} \sum_{i=1}^n \{g(\bar{x}) + g'(\bar{x})(x_i - \bar{x})\} \\ &= g(\bar{x}) + g'(\bar{x}) \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}) = g(\bar{x}). \end{aligned}$$

Mientras que,

$$\begin{aligned} s_y^2 &= \frac{1}{n-1} \sum_{i=1}^n (g(x_i) - \bar{g}(\mathbf{x}))^2 \approx \frac{1}{n-1} \sum_{i=1}^n (g(x_i) - g(\bar{x}))^2 \\ &\approx \frac{1}{n-1} \sum_{i=1}^n (g(\bar{x}) + g'(\bar{x})(x_i - \bar{x}) - g(\bar{x}))^2 \\ &= \frac{1}{n-1} \sum_{i=1}^n (g'(\bar{x})(x_i - \bar{x}))^2 = \{g'(\bar{x})\}^2 \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \\ &= \{g'(\bar{x})\}^2 s_x^2. \end{aligned}$$

Para  $g(x_i) = ax_i + b$  una transformación lineal, tenemos  $g'(x_i)$  y luego, se recupera los resultados dados en el ítem (d).

Por otro lado, si consideramos una aproximación de Taylor de segundo orden (en torno de  $\bar{x}$ ),

$$y_i \approx g(\bar{x}) + g'(\bar{x})(x_i - \bar{x}) + \frac{g''(\bar{x})}{2}(x_i - \bar{x})^2.$$

Es fácil notar que  $\bar{y} \approx g(\bar{x}) + g''(\bar{x})s_x^2/2$ .

**EJEMPLO 1.24.** Considere un conjunto de datos  $x_1, \dots, x_n$ . Verifique que

$$s^2 = \frac{1}{2n(n-1)} \sum_{i=1}^n \sum_{j=1}^n (x_i - x_j)^2.$$

Es fácil notar que

$$(x_i - x_j)^2 = ((x_i - \bar{x}) - (x_j - \bar{x}))^2 = (x_i - \bar{x})^2 + (x_j - \bar{x})^2 - 2(x_i - \bar{x})(x_j - \bar{x}).$$

De este modo,

$$\begin{aligned} \sum_{i=1}^n \sum_{j=1}^n (x_i - x_j)^2 &= \sum_{i=1}^n \sum_{j=1}^n \{(x_i - \bar{x})^2 + (x_j - \bar{x})^2 - 2(x_i - \bar{x})(x_j - \bar{x})\} \\ &= n \sum_{i=1}^n (x_i - \bar{x})^2 + n \sum_{j=1}^n (x_j - \bar{x})^2 - 2 \sum_{i=1}^n (x_i - \bar{x}) \sum_{j=1}^n (x_j - \bar{x}). \end{aligned}$$

Usando la Propiedad 1.23 (a), tenemos  $\sum_{i=1}^n (x_i - \bar{x}) = 0$  (y análogamente para  $\sum_{j=1}^n (x_j - \bar{x}) = 0$ ), luego

$$\sum_{i=1}^n \sum_{j=1}^n (x_i - x_j)^2 = 2n \sum_{i=1}^n (x_i - \bar{x})^2.$$

Lo que lleva a

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{2n(n-1)} \sum_{i=1}^n \sum_{j=1}^n (x_i - x_j)^2.$$

que es el resultado deseado.

PROPIEDAD 1.25. La mediana es el valor que minimiza la función

$$Q(a) = \sum_{i=1}^n |x_i - a|.$$

DEMOSTRACIÓN. Podemos escribir,

$$Q(a) = \sum_{x_i \geq a} (x_i - a) - \sum_{x_i < a} (x_i - a),$$

así

$$\frac{d}{da} Q(a) = - \sum_{x_i \geq a} 1 + \sum_{x_i < a} 1,$$

resolviendo la condición de primer orden  $dQ(a)/da = 0$ , tenemos

$$\sum_{x_i \geq a} 1 = \sum_{x_i < a} 1 \quad \Rightarrow \quad \hat{a} = \text{me},$$

por la propia definición de mediana.  $\square$

OBSERVACIÓN 1.26. Recuerde que

$$z = \text{signo}(z) \cdot |z|.$$

De este modo,  $\text{signo}(z) = z/|z|$  (o bien  $|z| = \text{signo}(z) \cdot z$ ). En efecto, tenemos que

$$\frac{d}{dz} |z| = \text{signo}(z), \quad \text{para } z \neq 0.$$

Por tanto, una forma alternativa de escribir  $dQ(a)/da$  es

$$\frac{d}{da} Q(a) = \sum_{i=1}^n \text{signo}(x_i - a),$$

es decir

$$\sum_{i=1}^n \text{signo}(x_i - a) = \sum_{i=1}^n \frac{1}{|x_i - a|} (x_i - a) = \sum_{i=1}^n \omega_i(a)(x_i - a), \quad (1.19)$$

donde  $\omega_i(a) = |x_i - a|^{-1}$  (Ecuación (1.19) es un promedio ponderado). Sin embargo, resolver la condición de primer orden

$$\sum_{i=1}^n \omega_i(a)(x_i - a) = 0, \quad (1.20)$$

con relación a  $a$  es bastante difícil. Una alternativa es considerar el Algoritmo 1 presentado a continuación.

Debemos destacar que la etapa de actualización dada en la Ecuación (1.21), equivale a resolver

$$\sum_{i=1}^n \omega_i(a_0)(x_i - a) = 0,$$

con relación a “ $a$ ”, que es muchísimo más simple que resolver (1.20) pues ahora las ponderaciones  $\omega_i(a_0)$  están *fijas*.



---

**Algoritmo 1:** Cálculo de la mediana usando un procedimiento basado en promedios iterativamente ponderados.

---

**Entrada:** Conjunto de  $n$  datos  $\mathbf{x} = (x_1, \dots, x_n)^\top$ , una aproximación inicial,  $a_0$  (por ejemplo,  $a_0 = \bar{x}$ ) y un valor de tolerancia ( $= 1 \cdot 10^{-6}$ )

**Salida :** Aproximación para el valor de la mediana,  $\hat{a} = \text{me}$ .

1 **begin**

2    Calcular

$$\omega_i(a_0) \leftarrow \frac{1}{|x_i - a_0|}, \quad i = 1, \dots, n.$$

3    Actualizar:

$$a_1 = \frac{1}{\sum_{j=1}^n \omega_j(a_0)} \sum_{i=1}^n \omega_i(a_0) x_i. \quad (1.21)$$

4    **if**  $|a_1 - a_0| < \text{tolerancia}$  **then**

5        **return**  $\text{me} = a_1$ , y detener el algoritmo.

6    **else**

7        hacer,  $a_0 \leftarrow a_1$

8        volver a Paso 2.

9    **end**

10 **end**

---

OBSERVACIÓN 1.27. ¿Qué deficiencias presenta este algoritmo?

- Este algoritmo converge a la mediana (aunque su velocidad de convergencia puede ser bastante lenta).
- En la convergencia, digamos  $\hat{a} = \text{me}$ , tendremos exactamente un “peso”  $\omega_i(\hat{a})$  indefinido (¿Ud. podría ‘adivinar’ cuál?).
- Una alternativa para el punto anterior es usar que<sup>1</sup>

$$\text{signo}(z) \approx \frac{z}{\sqrt{z^2 + \epsilon^2}}.$$

Por tanto, “cerca” del óptimo ( $\hat{a} = \text{me}$ ) podemos considerar los *pesos modificados*:

$$\tilde{\omega}_i(a) = \frac{1}{\sqrt{(x_i - a)^2 + \epsilon^2}}, \quad i = 1, \dots, n.$$

EJEMPLO 1.28. Considere el siguiente conjunto de datos:

$$\mathbf{x} = (2.40, 2.70, 2.80, 3.03, 3.40, 3.70, 28.95)^\top.$$

Evidentemente el valor 28.95 es una observación que se destaca y puede ser considerada como atípica. Los valores de la media muestral y el desviación estándar están dados por  $\bar{x} = 6.711$  y  $s_x = 9.816$ , respectivamente. En efecto, es posible especular que el valor de la media muestral no representa una buena estimación del

---

<sup>1</sup>Aproximación que mejora conforme  $\epsilon \rightarrow 0$ .

centro de los datos. Suponga que  $\mathbf{z}$  denota el conjunto donde hemos eliminado el valor “sospechoso” de 28.95.<sup>2</sup> En este caso obtenemos,

$$\bar{z} = \frac{18.03}{6} = 3.005, \quad s_z^2 = \frac{1.14075}{5} = 0.2282,$$

con  $s_z = 0.4777$ . Mientras que, cuando calculamos el valor de la mediana para ambos conjuntos de datos obtenemos

$$\text{me}(\mathbf{x}) = 3.03, \quad \text{me}(\mathbf{z}) = \frac{2.80 + 3.03}{2} = 2.915.$$

Es decir, la mediana es un procedimiento muy apropiado para cuantificar el valor central de un conjunto de datos en presencia de observaciones aberrantes o atípicas. Se dice entonces que la mediana es una estadística *robusta*.

Por otro lado, una alternativa robusta a la desviación estandar se conoce como la *desviación mediana absoluta (MAD)*, que es definida como:

$$\text{MAD}(\mathbf{x}) = \text{me}(|\mathbf{x} - \text{me}(\mathbf{x})|).$$

Evaluando esta cantidad para los conjuntos de datos  $\mathbf{x}$  y  $\mathbf{z}$ , obtenemos

$$\text{MAD}(\mathbf{x}) = \text{me}\{0.63, 0.33, 0.23, 0.00, 0.37, 0.67, 25.92\} = 0.37$$

$$\text{MAD}(\mathbf{z}) = \text{me}\{0.515, 0.215, 0.115, 0.115, 0.485, 0.785\} = \frac{0.215 + 0.485}{2} = 0.35.$$

Para hacer el MAD comparable con la desviación estándar, se define el *MAD normalizado* como:

$$\text{MADN}(\mathbf{x}) = \frac{\text{MAD}(\mathbf{x})}{0.6745}.$$

De este modo, obtenemos  $\text{MADN}(\mathbf{x}) = 0.5486$  mientras que  $\text{MADN}(\mathbf{z}) = 0.5189$ . Comparativamente con  $s_z = 0.4777$ , claramente MAD no se ve influenciado fuertemente por la presencia de observaciones atípicas. A continuación presentamos un fragmento de comandos en R para el cálculo de algunas estadísticas de resumen:

```
# introduciendo datos en la consola de R
> x <- c(2.40, 2.70, 2.80, 3.03, 3.40, 3.70, 28.95)
> x
[1] 2.40 2.70 2.80 3.03 3.40 3.70 28.95

# removiendo la 7a observación
> z <- x[-7]
> z
[1] 2.40 2.70 2.80 3.03 3.40 3.70

# cálculo de la media muestral
> mean(x)
[1] 6.711429
> mean(z)
[1] 3.005
```

<sup>2</sup>En ocasiones anotamos:  $\mathbf{z} = \mathbf{x}_{(7)} = (2.40, 2.70, 2.80, 3.03, 3.40, 3.70)^\top$ .

```
# cálculo de la mediana
> median(x)
[1] 3.03
> median(z)
[1] 2.915

# cálculo de la desviación estandar
> sd(x)
[1] 9.815978
> sd(z)
[1] 0.4776505
```

En R está disponible la función `mad`, para el cálculo del MAD o de su versión normalizada.

```
# cálculo del MAD
> abs(x - median(x))
[1] 0.63 0.33 0.23 0.00 0.37 0.67 25.92
> sort(abs(x - median(x)))
[1] 0.00 0.23 0.33 0.37 0.63 0.67 25.92

> mad(x, constant = 1) # MAD
[1] 0.37
> mad(x) # MAD normalizado
[1] 0.548562

> mad(z, constant = 1)
[1] 0.35
> mad(z)
[1] 0.51891
```

DEFINICIÓN 1.29 (Coeficiente de variación). Este coeficiente es una medida que compara la desviación estándar con el promedio de una muestra y es definido como

$$CV = s/\bar{x}, \quad \bar{x} \neq 0.$$

El coeficiente es particularmente útil para comparar dos o más muestras (o grupos). Un valor pequeño para el CV está asociado a una muestra homogénea.

OBSERVACIÓN 1.30. CV es una medida adimensional. Debemos resaltar que, en Econometría,  $1/CV$  es conocido como *razón de Sharpe*.

**1.2.3. Cálculo del promedio y varianza muestrales.** Es interesante notar que una mala implementación puede hacer que un buen algoritmo sea inútil. Un ejemplo de esto son las pobres implementaciones que son ofrecidas en Microsoft Excel. En efecto, [McCullough y Wilson \(1999, 2002, 2005\)](#) reporta una serie de falencias de los procedimientos estadísticos presentes en Excel. Por otro lado, software estadístico como R ([R Core Team, 2019](#)), o bien hojas de cálculo como Gnumeric<sup>3</sup> disponen de algoritmos confiables (ver, por ejemplo, [Keeling y Pavur, 2007](#)).

<sup>3</sup>URL: [www.gnumeric.org](http://www.gnumeric.org)

La definición de la varianza muestral dada en Ecuación (1.14) permite sugerir un algoritmo en 2-pasos para el cálculo de  $s^2$  (ver Algoritmo 2). Aunque se ha demostrado que este es un algoritmo estable (Chan y Lewis, 1979; Chan et al., 1983), puede no ser recomendable con grandes volúmenes de datos debido a que requiere “pasar a través de los datos dos veces”, es decir, requiere usar dos ciclos for. Mientras que la fórmula de Köning en (1.18) lleva a un algoritmo de 1-paso. En efecto, basado en la fórmula:

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n-1} \sum_{i=1}^n x_i^2 - \frac{n}{n-1} \bar{x}^2,$$

tenemos la implementación dada en el Algoritmo 3. Desafortunadamente, aunque este procedimiento es más veloz que el Algoritmo 2 (2-pasos), es bien sabido que puede llevar a cancelamientos ‘catastróficos’ y por tanto no es un método recomendable (ver Chan et al., 1983; Barlow, 1993). Para evitar este tipo de dificultades se ha propuesto algoritmos que explotan la definición de la media y varianza muestrales y que solo requieren de pasar por los datos una única vez.

---

**Algoritmo 2:** Varianza muestral usando un algoritmo de 2-pasos.

---

**Entrada:** Conjunto de  $n$  datos  $\mathbf{x} = (x_1, \dots, x_n)^\top$ .

**Salida :** Promedio y varianza muestrales,  $\bar{x}$  y  $s^2$ .

```

1 begin
2    $M \leftarrow x_1$ 
3   for  $i = 2$  to  $n$  do
4     |  $M \leftarrow M + x_i$ 
5   end
6    $M \leftarrow M/n$ 
7    $T \leftarrow (x_1 - M)^2$ 
8   for  $i = 2$  to  $n$  do
9     |  $T \leftarrow T + (x_i - M)^2$ 
10  end
11   $\bar{x} \leftarrow M$ 
12   $s^2 \leftarrow \frac{1}{n-1} T$ 
13 end
```

---

A continuación se describe el *algoritmo online* (1-paso) propuesto por West (1979). Considere una muestra de tamaño  $n$  y sea

$$\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i.$$

De este modo, evidentemente tenemos que

$$\begin{aligned} \bar{x}_n &= \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} \left( \sum_{i=1}^{n-1} x_i + x_n \right) = \frac{1}{n} \left( (n-1)\bar{x}_{n-1} + x_n \right) \\ &= \frac{1}{n} \left( n\bar{x}_{n-1} - \bar{x}_{n-1} + x_n \right) = \bar{x}_{n-1} + \frac{x_n - \bar{x}_{n-1}}{n}. \end{aligned} \quad (1.22)$$

---

**Algoritmo 3:** Varianza muestral usando un algoritmo de 1-paso.

---

**Entrada:** Conjunto de  $n$  datos  $\mathbf{x} = (x_1, \dots, x_n)^\top$ .

**Salida :** Promedio y varianza muestrales,  $\bar{x}$  y  $s^2$ .

```

1 begin
2    $M \leftarrow x_1$ 
3    $T \leftarrow x_1^2$ 
4   for  $i = 2$  to  $n$  do
5      $M \leftarrow M + x_i$ 
6      $T \leftarrow T + x_i^2$ 
7   end
8    $\bar{x} \leftarrow M/n$ 
9    $s^2 \leftarrow \frac{1}{n-1}T - \frac{n}{n-1}\bar{x}^2$ 
10 end
```

---

La base del algoritmo propuesto por [West \(1979\)](#) es la relación recursiva definida en la Ecuación (1.22). Sea  $\delta_n = x_n - \bar{x}_{n-1}$ , también podemos definir un algoritmo recursivo para el cálculo de la varianza muestral. En efecto, considere

$$\begin{aligned}
T_n &= \sum_{i=1}^n (x_i - \bar{x}_n)^2 = \sum_{i=1}^{n-1} (x_i - \bar{x}_n)^2 + (x_n - \bar{x}_n)^2 \\
&= \sum_{i=1}^{n-1} (x_i - \bar{x}_{n-1} - \delta_n/n)^2 + (x_n - \bar{x}_{n-1} - \delta_n/n)^2 \\
&= \sum_{i=1}^{n-1} \left[ (x_i - \bar{x}_{n-1})^2 - 2\frac{\delta_n}{n}(x_i - \bar{x}_{n-1}) + \frac{\delta_n^2}{n^2} + \left(\delta_n - \frac{\delta_n}{n}\right)^2 \right]
\end{aligned}$$

Sabemos por Propiedad 1.23 (a), que

$$\sum_{i=1}^{n-1} (x_i - \bar{x}_{n-1}) = 0,$$

De este modo, podemos escribir la suma de cuadrados  $T_n$ , como:

$$\begin{aligned}
T_n &= \sum_{i=1}^{n-1} (x_i - \bar{x}_{n-1})^2 + (n-1)\frac{\delta_n^2}{n^2} + \left(1 - \frac{1}{n}\right)^2 \delta_n^2 \\
&= T_{n-1} + \left(1 - \frac{1}{n}\right)\delta_n^2.
\end{aligned} \tag{1.23}$$

Ecuaciones (1.22) y (1.23) llevan al Algoritmo 4 ([West, 1979](#)), cuya definición se presenta a continuación.

[Chan y Lewis \(1979\)](#) introdujeron una medida que permite evaluar la sensibilidad de una muestra  $\mathbf{x} = (x_1, \dots, x_n)^\top$  cuando debemos desarrollar el cálculo de su varianza muestral.

---

**Algoritmo 4:** Promedio y varianza muestrales usando un algoritmo on-line.

---

**Entrada:** Conjunto de  $n$  datos  $\mathbf{x} = (x_1, \dots, x_n)^\top$ .

**Salida :** Promedio y varianza muestrales,  $\bar{x}$  y  $s^2$ .

```

1 begin
2    $M \leftarrow x_1$ 
3    $T \leftarrow 0$ 
4   for  $i = 2$  to  $n$  do
5      $\delta \leftarrow (x_i - M)/i$ 
6      $M \leftarrow M + \delta$ 
7      $T \leftarrow T + i(i - 1)\delta^2$ 
8   end
9    $\bar{x} \leftarrow M$ 
10   $s^2 \leftarrow \frac{1}{n - 1}T$ 
11 end
```

---

Sea

$$\|\mathbf{x}\|_2 = \sqrt{\sum_{i=1}^n x_i^2},$$

la norma Euclidiana para el conjunto de datos  $\mathbf{x}$ . De este modo, se define el *número condición* como:

$$\kappa = \frac{\|\mathbf{x}\|_2}{\sqrt{n-1}s}.$$

Esta medida permite cuantificar el efecto de introducir errores en los datos y como éstos son magnificados en el cálculo de la varianza. Es interesante notar que el número condición puede ser utilizado para evaluar la estabilidad de un algoritmo para el cálculo de  $s^2$ . Además podemos verificar fácilmente que el número condición está relacionado con el coeficiente de variación. Considere el siguiente ejemplo.

EJEMPLO 1.31. Sea  $\mathbf{x} = (x_1, \dots, x_n)^\top$  una muestra de datos. Verifique que

$$\kappa^2 = 1 + \frac{n}{n-1} CV^{-2}. \quad (1.24)$$

En efecto, sabemos que

$$\sum_{i=1}^n x_i^2 = \sum_{i=1}^n (x_i - \bar{x})^2 + n\bar{x}^2,$$

dividiendo ámbos términos por  $(n-1)s^2$ , obtenemos

$$\kappa^2 = \frac{\sum_{i=1}^n x_i^2}{(n-1)s^2} = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{(n-1)s^2} + \left(\frac{n}{n-1}\right) \frac{\bar{x}^2}{s^2}.$$

Además  $\sum_{i=1}^n (x_i - \bar{x})^2 = (n-1)s^2$ , entonces podemos escribir

$$\kappa^2 = 1 + \left(\frac{n}{n-1}\right) \left(\frac{\bar{x}}{s}\right)^2.$$

tenemos  $CV = s/\bar{x}$  y el resultado sigue.

Desde (1.24), sigue que

$$\kappa = \sqrt{1 + n CV^{-2} / (n - 1)},$$

es decir, a menos que CV sea bastante grande  $\kappa \approx CV^{-1}$  será una buena aproximación.

Finalmente debemos destacar que Chan et al. (1983) propusieron un algoritmo extremadamente estable para el cálculo de la varianza basado en un procedimiento de *suma acumulada por pares* el cual puede ser fácilmente paralelizado.

**1.2.4. Medidas de forma.** Momentos de orden mayor, o estadísticas involucrando potencias de orden mayor de los datos observados permiten caracterizar la forma de la densidad que describe el mecanismo que genera las  $n$  realizaciones  $x_1, \dots, x_n$  de nuestra variable de interés. A continuación revisamos la definición de los coeficientes de asimetría y curtosis, los que caracterizan el grado de asimetría de una distribución en torno de su promedio y el grado de agudeza o achatamiento de una distribución al ser comparada contra la distribución normal (gaussiana).

DEFINICIÓN 1.32 (Coeficiente de asimetría). Considere  $M_3$  el tercer momento muestral en torno del promedio. Entonces, se define el *coeficiente de asimetría* (o sesgo) como:

$$b_1 = \frac{M_3}{s^3} = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s} \right)^3.$$

OBSERVACIÓN 1.33.  $b_1$  también es conocido como coeficiente de asimetría de Fisher y se caracteriza por ser una medida adimensional así como por ser invariante bajo traslaciones del origen y transformaciones de escala. Considere los siguientes gráficos:




Figura 1. (a) distribuciones simétricas, (b) distribución con asimetría negativa (—) y asimetría positiva (---).

- Si  $b_1 = 0$  la distribución es simétrica con relación a la media.
- Si  $b_1 > 0$  la distribución tiene sesgo positivo (o hacia la derecha), en cuyo caso la distribución tiende a concentrarse en valores altos de la variable. En caso contrario ( $b_1 < 0$ ), diremos que su sesgo es negativo (o que es asimétrica hacia la izquierda).

OBSERVACIÓN 1.34. Se han definido varios índices de simetría, por ejemplo el *coeficiente de asimetría de Galton*:

$$b_G = \frac{(Q_3 - Q_2) - (Q_2 - Q_1)}{Q_3 - Q_1}.$$

DEFINICIÓN 1.35 (Coeficiente de curtosis). Considere  $M_4$  el cuarto momento muestral en torno del promedio. Entonces, se define el *coeficiente de curtosis* (o achataamiento) como:

$$b_2 = \frac{M_4}{s^4} - 3 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s} \right)^4 - 3.$$

OBSERVACIÓN 1.36. El término  $-3$  hace que  $b_2 = 0$  cuando los datos siguen una distribución normal (gaussiana) en cuyo caso decimos que la distribución es *mesocúrtica*. Considere la figura a continuación:




Figura 2. Distintos grados de curtosis: distribución leptocúrtica ( $\cdots$ ), mesocúrtica ( $\text{—}$ ) y platicúrtica ( $\text{-- --}$ ).

Si  $b_2 > 0$  la distribución de los datos es más aguzada que la distribución normal (distribución *leptocúrtica*), mientras que si  $b_2 < 0$  la distribución es más achatada que la normal (distribución *platicúrtica*).



**1.2.5. Estadísticas de resumen para datos agrupados.** Cuando los datos han sido tabulados en una *tabla de frecuencias* se dice que los datos se encuentran agrupados. El objetivo de esta sección es proporcionar fórmulas para las medidas de posición (o tendencia central), de dispersión y de forma sin la necesidad de desagregar los datos. Primeramente vamos a suponer que la variable de interés es discreta. Considere el siguiente ejemplo:

EJEMPLO 1.37. Se consultó las fichas de los empleados de una fábrica, registrándose el *número de cargas familiares* y se obtuvo los siguientes datos:

1 2 4 2 2 2 3 2 1 1 0 2 2  
0 2 2 1 2 2 3 1 2 2 1 2

En cuyo caso, tenemos que la tabla de frecuencias asociada asume la forma:

Cargas familiares	Número de empleados	Porcentaje de empleados	Num. acumulado de empleados	Porcentaje acumulado
0	2	8 %	2	8 %
1	6	23 %	8	32 %
2	14	56 %	22	88 %
3	2	8 %	24	96 %
4	1	4 %	25	100 %
Total	25	100 %	–	–

Podemos notar que los datos de interés corresponden a una variable discreta  $x$  (número de cargas familiares) que tiene  $k$  categorías. De este modo, podemos construir la siguiente tabla

Variable	Frecuencia Absoluta	Frecuencia Relativa	Frec. Abs. Acumulada	Frec. Rel. Acumulada
$x_1$	$n_1$	$f_1$	$N_1$	$F_1$
$x_2$	$n_2$	$f_2$	$N_2$	$F_2$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$x_k$	$n_k$	$f_k$	$N_k$	$F_k$
Total	$n$	1	–	–

donde

$$f_i = \frac{n_i}{n}, \quad N_i = \sum_{j=1}^i n_j, \quad F_i = \sum_{j=1}^i f_j, \quad (1.25)$$

para  $i = 1, \dots, k$ . Evidentemente tenemos que

$$\sum_{i=1}^k n_i = n, \quad N_k = n, \quad \sum_{i=1}^k f_i = 1, \quad F_k = 1. \quad (1.26)$$

En este contexto tenemos que la media y varianzas muestrales están dados por

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k n_i x_i = \sum_{i=1}^k f_i x_i,$$

$$s^2 = \frac{1}{n-1} \sum_{i=1}^k n_i (x_i - \bar{x})^2.$$

Para los datos del Ejemplo 1.37, es fácil notar que

$$\bar{x} = \frac{2 \cdot 0 + 6 \cdot 1 + 14 \cdot 2 + 2 \cdot 3 + 1 \cdot 4}{25} = \frac{44}{25} = 1.760$$

$$s^2 = \frac{2(0 - 1.76)^2 + 6(1 - 1.76)^2 + 14(2 - 1.76)^2 + 2(3 - 1.76)^2 + 1(4 - 1.76)^2}{25 - 1}$$

$$= \frac{18.56}{24} = 0.773$$

Para datos continuos  $x_1, \dots, x_n$  tenemos la tabla de frecuencias:

Marca de clase	Frecuencia Absoluta	Frecuencia Relativa	Frec. Abs. Acumulada	Frec. Rel. Acumulada
$C_1$	$n_1$	$f_1$	$N_1$	$F_1$
$C_2$	$n_2$	$f_2$	$N_2$	$F_2$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$C_k$	$n_k$	$f_k$	$N_k$	$F_k$
Total	$n$	1	—	—

donde  $f_i$ ,  $N_i$  y  $F_i$ , para cada una de las  $k$  categorías ha sido definido en (1.25) y (1.26), mientras que la *marca de clase* es definida como:

$$C_i = \frac{L_i + U_i}{2}, \quad i = 1, \dots, k,$$

con  $L_i$  y  $U_i$  los límites inferior y superior de cada intervalo, respectivamente. Note que la marca de clase es un representante de la clase (intervalo) respectiva. Análogamente a caso de una tabla de frecuencias para datos discretos, tenemos que:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k n_i C_i = \sum_{i=1}^k f_i C_i,$$

$$s^2 = \frac{1}{n-1} \sum_{i=1}^k n_i (C_i - \bar{x})^2.$$

EJEMPLO 1.38. Considere los *precios de cierre* de acciones una determinada empresa nacional, dados por:

179	173	181	170	158	174	172	166	194	185
162	187	198	177	178	165	154	188	166	171
175	182	167	169	172	186	172	176	168	187

cuya tabla de frecuencias asume la forma:

Precio de cierre	Marca de clase	Número de días	Porcentaje de días	Num. de días acumulado	Porcentaje acumulado
(150,160]	155	2	7 %	2	7 %
(160,170]	165	8	27 %	10	34 %
(170,180]	175	11	36 %	21	70 %
(180,190]	185	7	23 %	28	93 %
(190,200]	195	2	7 %	30	100 %
Total	—	30	100 %	—	—

De este modo, podemos calcular la media y varianza muestrales desde la tabla de frecuencias, como:

$$\bar{x} = \frac{2 \cdot 155 + 8 \cdot 165 + 11 \cdot 175 + 7 \cdot 185 + 2 \cdot 195}{30} = \frac{5240}{30} = 174.667$$

mientras que,


$$\sum_{i=1}^5 n_i (C_i - \bar{x})^2 = 2(155 - 174.667)^2 + 8(165 - 174.667)^2 + 11(175 - 174.667)^2 \\ + 7(185 - 174.667)^2 + 2(195 - 174.667)^2 = 3096.667,$$

de este modo,  $s^2 = 3096.667/(30-1) = 106.782$ . Es interesante notar que los valores de la media y varianza muestrales obtenidos a partir de una tabla de frecuencias corresponden a una *aproximación* de los valores obtenidos a partir de los *datos a granel*. En efecto, el siguiente fragmento en R considera los datos crudos:

```
# precios de cierre (datos a granel)
> x <- c(179, 173, 181, 170, 158, 174, 172, 166, 194, 185,
+ 162, 187, 198, 177, 178, 165, 154, 188, 166, 171, 175,
+ 182, 167, 169, 172, 186, 172, 176, 168, 187)

# cálculo de media y varianza muestrales
> mean(x)
[1] 175.0667
> var(x)
[1] 105.7195
```

Considere la función de distribución acumulada



de este modo, podemos usar interpolación lineal para determinar la mediana en datos agrupados. En efecto,

$$\frac{1/2 - F_{i-1}}{F_i - F_{i-1}} = \frac{\text{me} - L_i}{U_i - L_i},$$

es decir,

$$(1/2 - F_{i-1})(U_i - L_i) = (\text{me} - L_i)(F_i - F_{i-1}),$$

o bien

$$\text{me} = L_i + \frac{1/2 - F_{i-1}}{F_i - F_{i-1}}(U_i - L_i) = L_i + \frac{1/2 - F_{i-1}}{F_i - F_{i-1}} a_i,$$

donde  $a_i = U_i - L_i$ , representa la amplitud de la clase mediana. Recordando que  $F_i = \sum_{j=1}^i f_j$ , tenemos

$$F_i - F_{i-1} = \sum_{j=1}^i f_j - \sum_{j=1}^{i-1} f_j = f_i + \sum_{j=1}^{i-1} f_j - \sum_{j=1}^{i-1} f_j = f_i.$$

Además, como  $f_i = n_i/n$  y  $F_i = N_i/n$ , podemos re-escribir la *mediana para datos agrupados* como:

$$\begin{aligned} \text{me} &= L_i + \frac{1/2 - F_{i-1}}{f_i} a_i = L_i + \frac{1/2 - F_{i-1}}{n_i/n} a_i \\ &= L_i + \frac{n/2 - N_{i-1}}{n_i} a_i \end{aligned}$$

Siguiendo exactamente la misma lógica, tenemos que el percentil  $k$ -ésimo, digamos  $P_k$  es dado por

$$P_k = L_i + \frac{k/100 - F_{i-1}}{f_i} a_i,$$

o bien

$$P_k = L_i + \frac{n(k/100) - N_{i-1}}{n_i} a_i.$$

EJEMPLO 1.39. Los trabajadores de una empresa, cuya tarea es clasificar y envasar fruta, obtuvieron los siguientes salarios semanales (clasificados según sexo).

Ingreso (UM)	Mujeres	Hombres
65 - 75	10	0
75 - 85	15	0
85 - 95	60	5
95 - 105	15	10
105 - 115	10	50
115 - 125	0	25
125 - 135	0	10
Total	110	100

Consideraremos solamente el grupo de mujeres y dejaremos el análisis del grupo de hombres y el total de trabajadores como ejercicio. Así, la tabla de frecuencias para el grupo de mujeres adopta la forma:

Ingreso (UM)	$C_i$	$n_i$	$f_i$	$N_i$	$F_i$
65 - 75	70	10	0.090	10	0.090
75 - 85	80	15	0.136	25	0.226
85 - 95	90	60	0.548	85	0.774
95 - 105	100	15	0.136	100	0.910
105 - 115	110	10	0.090	110	1.000
Total	-	110	1.000	-	-

En este caso, tenemos  $n = 110$  y  $\sum_{i=1}^5 n_i C_i = 9900$ . De este modo, la media aritmética para el grupo de mujeres es:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^5 n_i C_i = \frac{9900}{110} = 90 \text{ (UM)}.$$

Para calcular la mediana, primero debemos ubicar el intervalo mediano. En efecto, debemos ubicar la primera frecuencia relativa acumulada ( $F_i$ ) que supere 0.5 (o bien, frecuencia absoluta acumulada ( $N_i$ ) que supere  $n/2$ ). De este modo el intervalo mediano es  $(85, 95]$ . Además,  $a_i = 10$  para todos los intervalos. De este modo,

$$\text{me} = L_i + \frac{1/2 - F_{i-1}}{f_i} a_i,$$

donde  $L_i = 85$ ,  $F_{i-1} = 0.226$ ,  $f_i = 0.548$  y  $a_i = 10$ , luego

$$\text{me} = 85 + \frac{0.500 - 0.226}{0.548} \cdot 10 = 85 + 0.5 \cdot 10 = 90 \text{ (UM)}.$$

Por otro lado,

$$s^2 = \frac{1}{n-1} \left( \sum_{i=1}^5 n_i C_i^2 - n \bar{x}^2 \right).$$

En nuestro caso,

$$\sum_{i=1}^5 n_i C_i^2 = 902\,000, \quad \bar{x}^2 = 8\,100.$$

Así,

$$\begin{aligned} s^2 &= \frac{1}{110-1} (902\,000 - 110 \cdot 8\,100^2) = \frac{1}{109} (902\,000 - 891\,000) \\ &= \frac{11\,000}{109} = 100.9174 \text{ (UM)}^2. \end{aligned}$$

Además, tenemos que  $s = \sqrt{11\,000/109} = 10.0458$  (UM). Mientras que

$$\text{CV} = \frac{10.0458}{90} = 0.1116.$$

Podemos evaluar la simetría usando el coeficiente de Galton. Por tanto, debemos calcular  $Q_1$  y  $Q_3$ , como:

$$\begin{aligned} Q_1 &= 85 + \frac{0.250 - 0.226}{0.548} \cdot 10 = 85.438 \\ Q_3 &= 85 + \frac{0.750 - 0.226}{0.548} \cdot 10 = 94.562, \end{aligned}$$

de este modo  $IQR = 9.1240$ , y

$$\begin{aligned} \gamma_G &= \frac{(Q_3 - Q_2) - (Q_2 - Q_1)}{Q_3 - Q_1} \\ &= \frac{(94.562 - 90) - (90 - 85.438)}{9.124} = \frac{4.562 - 4.562}{9.124} = 0.000 \end{aligned}$$

Es decir, la distribución de los datos es simétrica.

Mientras que la moda interpolada, es dada por

$$\text{mo} = L_m + \frac{\Delta_1}{\Delta_1 + \Delta_2} a_m,$$

donde

- $L_m$  es el límite inferior de la clase modal.
- $\Delta_1 = n_m - n_{m-1}$  con  $n_m$  la frecuencia absoluta de la clase modal, mientras que  $n_{m-1}$  es la frecuencia absoluta de la clase anterior a la clase modal.
- $\Delta_2 = n_m - n_{m+1}$  con  $n_{m+1}$  la frecuencia absoluta de la clase posterior a la clase modal.
- $a_m$  es la amplitud de la clase modal.

OBSERVACIÓN 1.40. La clase modal es aquella que tiene la mayor frecuencia relativa. Note además, que en una tabla de frecuencia podría existir más de una clase modal.

### 1.3. Covarianza y correlación

Considere  $\mathbf{x} = (x_1, \dots, x_n)^\top$  y  $\mathbf{y} = (y_1, \dots, y_n)^\top$  dos vectores de datos con  $n$  observaciones. En esta sección se introducen medidas de asociación entre variables continuas y ordinales. Primeramente se introduce el concepto de covarianza.

DEFINICIÓN 1.41 (Covarianza). Para el conjunto  $(x_1, y_1), \dots, (x_n, y_n)$ , se define la covarianza como una medida de variabilidad conjunta de dos variables cuantitativas, como:

$$\text{cov}(\mathbf{x}, \mathbf{y}) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}).$$

OBSERVACIÓN 1.42. En efecto, es fácil apreciar que  $\text{cov}(\mathbf{x}, \mathbf{x}) = s_x^2$ . Además, evidentemente la covarianza está relacionada con el producto interno entre dos vectores  $n$ -dimensionales,  $\langle \mathbf{u}, \mathbf{v} \rangle = \sum_{i=1}^n u_i v_i$ .

EJEMPLO 1.43. Tal como en la Propiedad 1.23 (b), a continuación derivamos una expresión alternativa para la covarianza. En efecto,

$$\begin{aligned} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) &= \sum_{i=1}^n x_i(y_i - \bar{y}) - \bar{x} \sum_{i=1}^n (y_i - \bar{y}) \\ &= \sum_{i=1}^n x_i y_i - \bar{y} \sum_{i=1}^n x_i = \sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}. \end{aligned}$$

De este modo, podemos escribir

$$\text{cov}(\mathbf{x}, \mathbf{y}) = \frac{1}{n-1} \left( \sum_{i=1}^n x_i y_i - n\bar{x}\bar{y} \right).$$

PROPIEDAD 1.44. Tenemos que

$$\text{cov}(a\mathbf{x} + b, c\mathbf{y} + d) = ac \text{cov}(\mathbf{x}, \mathbf{y}).$$

DEMOSTRACIÓN. Sea  $z_i = ax_i + b$  y  $w_i = cy_i + d$  para  $i = 1, \dots, n$ . Entonces  $\bar{z} = a\bar{x} + b$  y  $\bar{w} = c\bar{y} + d$ , luego

$$\text{cov}(\mathbf{z}, \mathbf{w}) = \frac{1}{n-1} \sum_{i=1}^n (z_i - \bar{z})(w_i - \bar{w}),$$

como  $z_i - \bar{z} = a(x_i - \bar{x})$  y  $w_i - \bar{w} = c(y_i - \bar{y})$ . Entonces

$$\text{cov}(\mathbf{z}, \mathbf{w}) = \frac{1}{n-1} ac \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}),$$

que es el resultado deseado.  $\square$

La covarianza permite medir la asociación, pero depende de la unidad de medida. Una alternativa es usar una medida conocida como *correlación*.

DEFINICIÓN 1.45 (Correlación). La correlación entre  $\mathbf{x}$  e  $\mathbf{y}$  es la covarianza de sus versiones estandarizadas. Es decir,

$$\begin{aligned} \text{cor}(\mathbf{x}, \mathbf{y}) &= \frac{1}{n-1} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right) \left( \frac{y_i - \bar{y}}{s_y} \right) \\ &= \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \\ &= \frac{\text{cov}(\mathbf{x}, \mathbf{y})}{s_x s_y}. \end{aligned}$$

OBSERVACIÓN 1.46.  $\text{cor}(\mathbf{x}, \mathbf{y})$  es una medida adimensional.

EJERCICIO 1.47. Muestre que

$$\text{cor}(a\mathbf{x} + b, c\mathbf{y} + d) = \pm \text{cor}(\mathbf{x}, \mathbf{y}).$$

EJEMPLO 1.48. Verifique que

$$s_{x+y}^2 = s_x^2 + s_y^2 + 2 \text{cov}(\mathbf{x}, \mathbf{y}) = s_x^2 + s_y^2 + 2 \text{cor}(\mathbf{x}, \mathbf{y}) s_x s_y.$$

En efecto, podemos notar que

$$\begin{aligned} s_{x+y}^2 &= \frac{1}{n-1} \sum_{i=1}^n ((x_i - \bar{x}) + (y_i - \bar{y}))^2 \\ &= \frac{1}{n-1} \left( \sum_{i=1}^n (x_i - \bar{x})^2 + \sum_{i=1}^n (y_i - \bar{y})^2 + 2 \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \right) \\ &= s_x^2 + s_y^2 + 2 \text{cov}(\mathbf{x}, \mathbf{y}) \end{aligned}$$

OBSERVACIÓN 1.49. Cuando  $\text{cor}(\mathbf{x}, \mathbf{y}) = 0$  diremos que  $\mathbf{x}$  e  $\mathbf{y}$  son *no correlacionados*.

OBSERVACIÓN 1.50. Si  $\mathbf{x}$  e  $\mathbf{y}$  son no correlacionados, entonces

$$s_{x+y}^2 = s_x^2 + s_y^2.$$

PROPIEDAD 1.51. Tenemos que  $\{\text{cor}(\mathbf{x}, \mathbf{y})\}^2 \leq 1$ .

DEMOSTRACIÓN. Usando la desigualdad de Cauchy-Schwarz<sup>4</sup>, tenemos que

$$\left( \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \right)^2 \leq \left( \sum_{i=1}^n (x_i - \bar{x})^2 \right) \left( \sum_{i=1}^n (y_i - \bar{y})^2 \right),$$

<sup>4</sup>Recuerde que  $\langle \mathbf{u}, \mathbf{v} \rangle^2 \leq \|\mathbf{u}\|^2 \|\mathbf{v}\|^2$

es decir,

$$\left(\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})\right)^2 \leq \left(\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2\right) \left(\frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2\right)$$

$$\{\text{cov}(\mathbf{x}, \mathbf{y})\}^2 \leq s_x^2 s_y^2.$$

De este modo,

$$\frac{\text{cov}^2(\mathbf{x}, \mathbf{y})}{s_x^2 s_y^2} \leq 1.$$

□

Evidentemente, desde la propiedad anterior tenemos  $-1 \leq \text{cor}(\mathbf{x}, \mathbf{y}) \leq 1$ .

Para datos que no son de naturaleza continua, una alternativa es reemplazar el valor de  $x_i$  ( $y_i$ ) por su rango,  $R_i$  ( $S_i$ ) que corresponde a un valor en el conjunto  $\{1, 2, \dots, n\}$ . Considere la siguiente definición

DEFINICIÓN 1.52 (Coeficiente de correlación de Spearman). Suponga el conjunto de datos pareados  $(x_1, y_1), \dots, (x_n, y_n)$  y sea  $R_i$  el rango de  $x_i$  y  $S_i$  el rango de  $y_i$ , para  $i = 1, \dots, n$ . Entonces el coeficiente de correlación de Spearman es dado por

$$r_S = \frac{\sum_{i=1}^n (R_i - \bar{R})(S_i - \bar{S})}{\sqrt{\sum_{i=1}^n (R_i - \bar{R})^2 \sum_{i=1}^n (S_i - \bar{S})^2}}.$$

Considere

$$D = \sum_{i=1}^n (R_i - S_i)^2,$$

y suponga que no existen empates entre los  $x$ 's e  $y$ 's, entonces podemos escribir

$$r_S = 1 - \frac{6D}{n(n^2 - 1)}.$$

OBSERVACIÓN 1.53. Análogamente a los resultados expuestos en la Sección 1.2.3, podemos llevar a cabo el cálculo de la covarianza entre  $\mathbf{x}$  e  $\mathbf{y}$  de manera eficiente considerando,

$$C_n = \sum_{i=1}^n (x_i - \bar{x}_n)(y_i - \bar{y}_n) = \sum_{i=1}^{n-1} (x_i - \bar{x}_n)(y_i - \bar{y}_n) + (x_n - \bar{x}_n)(y_n - \bar{y}_n).$$

Sea  $\delta_n = x_n - \bar{x}_{n-1}$ , de este modo podemos escribir:

$$x_i - \bar{x}_n = x_i - \bar{x}_{n-1} - \frac{\delta_n}{n}, \quad x_n - \bar{x}_n = \left(1 - \frac{1}{n}\right)\delta_n,$$

y análogamente,

$$y_i - \bar{y}_n = y_i - \bar{y}_{n-1} - \frac{\eta_n}{n}, \quad y_n - \bar{y}_n = \left(1 - \frac{1}{n}\right)\eta_n,$$

con  $\eta_n = y_n - \bar{y}_{n-1}$ . Notando que

$$\begin{aligned} (x_i - \bar{x}_n)(y_i - \bar{y}_n) &= \left\{ (x_i - \bar{x}_{n-1}) - \frac{\delta_n}{n} \right\} \left\{ (y_i - \bar{y}_{n-1}) - \frac{\eta_n}{n} \right\} \\ &= (x_i - \bar{x}_{n-1})(y_i - \bar{y}_{n-1}) - (x_i - \bar{x}_{n-1}) \frac{\eta_n}{n} \\ &\quad - \frac{\delta_n}{n} (y_i - \bar{y}_{n-1}) + \frac{\delta_n \eta_n}{n^2}. \end{aligned}$$



Sumando sobre  $\{1, \dots, n-1\}$  y recordando que

$$\sum_{i=1}^{n-1} (x_i - \bar{x}_{n-1}) = 0, \quad \sum_{i=1}^{n-1} (y_i - \bar{y}_{n-1}) = 0,$$

sigue que

$$\begin{aligned} C_n &= \sum_{i=1}^{n-1} (x_i - \bar{x}_{n-1})(y_i - \bar{y}_{n-1}) + \left(\frac{n-1}{n^2}\right) \delta_n \eta_n + \left(\frac{n-1}{n}\right)^2 \delta_n \eta_n \\ &= C_{n-1} + \left(\frac{n-1}{n}\right) \delta_n \eta_n. \end{aligned}$$

Así, haciendo  $\text{cov}_n = \text{cov}(\mathbf{x}, \mathbf{y})$ , tenemos

$$\text{cov}_n = \frac{1}{n-1} C_n = \frac{1}{n-1} \left\{ C_{n-1} + \left(\frac{n-1}{n}\right) \delta_n \eta_n \right\},$$

pero  $C_{n-1} = ((n-1)-1) \text{cov}_{n-1} = (n-1) \text{cov}_{n-1} - \text{cov}_{n-1}$ . De este modo,

$$\begin{aligned} \text{cov}_n &= \frac{1}{n-1} \left\{ (n-1) \text{cov}_{n-1} - \text{cov}_{n-1} + \left(\frac{n-1}{n}\right) \delta_n \eta_n \right\} \\ &= \text{cov}_{n-1} - \frac{\text{cov}_{n-1}}{n-1} + \frac{(x_n - \bar{x}_{n-1})(y_n - \bar{y}_{n-1})}{n}. \end{aligned}$$

Este desarrollo lleva al siguiente algoritmo: Además, es fácil notar que modificando

---

**Algoritmo 5:** Covarianza muestral usando un algoritmo online.

---

**Entrada:** Conjuntos de  $n$  datos  $\mathbf{x} = (x_1, \dots, x_n)^\top$  e  $\mathbf{y} = (y_1, \dots, y_n)^\top$ .

**Salida :** Covarianza muestral,  $\text{cov}(\mathbf{x}, \mathbf{y})$ .

```

1 begin
2   M ← x1
3   N ← y1
4   C ← 0
5   for i = 2 to n do
6     δ ← (xi - M)/i
7     η ← (yi - N)/i
8     M ← M + δ
9     N ← N + η
10    C ← C -  $\frac{C}{i-1}$  + i δ η
11  end
12  cov(x, y) ← C.
13 end
```

---

ligeramente el Algoritmo 5 podemos obtener también  $\bar{x}_n$ ,  $\bar{y}_n$ ,  $s_x^2$  y  $s_y^2$ .

#### 1.4. Estadísticas descriptivas multivariadas

Considere que nuestro interés es estudiar  $p \geq 2$  variables (características) de interés asociadas a una muestra aleatoria  $\mathbf{x}_1, \dots, \mathbf{x}_n$  donde cada  $\mathbf{x}_i = (x_{i1}, \dots, x_{ip})^\top$  es un

vector  $p$ -dimensional. Note que, podemos disponer la información en una *matriz de datos*

$$\mathbf{X} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix} = \begin{pmatrix} \mathbf{x}_1^\top \\ \mathbf{x}_2^\top \\ \vdots \\ \mathbf{x}_n^\top \end{pmatrix}.$$

Análogamente a la media y varianza muestrales  $\bar{x}$  y  $s^2$  unidimensionales, respectivamente, podemos definir sus contrapartes multivariadas como:

$$\bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i,$$

$$\mathbf{S} = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^\top.$$

Además, la matriz de correlación entre las  $p$  variables de interés, es dada por:

$$\mathbf{R} = (r_{ij}),$$

donde

$$r_{ij} = \frac{\sum_{k=1}^n (x_{ki} - \bar{x}_i)(x_{kj} - \bar{x}_j)}{\sqrt{\sum_{k=1}^n (x_{ki} - \bar{x}_i)^2 \sum_{k=1}^n (x_{kj} - \bar{x}_j)^2}} = \frac{s_{ij}}{\sqrt{s_{ii}s_{jj}}},$$

con  $\mathbf{S} = (s_{ij})$  y  $\bar{x}_i = (\sum_{k=1}^n x_{ki})/n$ . Sea,  $\mathbf{D} = \text{diag}(s_{11}, s_{22}, \dots, s_{pp})$ , así podemos escribir

$$\mathbf{R} = \mathbf{D}^{-1/2} \mathbf{S} \mathbf{D}^{-1/2}.$$

OBSERVACIÓN 1.54. Algunas propiedades del vector de medias y la matriz de covarianza, surgen de escribir formas compactas que dependen de la matriz de datos  $\mathbf{X} = (x_{ij}) \in \mathbb{R}^{n \times p}$ . En efecto,

$$\bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i = \frac{1}{n} \mathbf{X}^\top \mathbf{1}.$$

Además,

$$\begin{aligned} \mathbf{Q} &= \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^\top = \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})\mathbf{x}_i^\top - \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})\bar{\mathbf{x}}^\top \\ &= \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^\top - \bar{\mathbf{x}} \sum_{i=1}^n \mathbf{x}_i^\top = \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^\top - n \bar{\mathbf{x}} \bar{\mathbf{x}}^\top \end{aligned}$$

Es fácil notar que  $\sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^\top = \mathbf{X}^\top \mathbf{X}$ , de este modo,

$$\begin{aligned} \mathbf{S} &= \frac{1}{n-1} \mathbf{Q} = \frac{1}{n-1} \left\{ \mathbf{X}^\top \mathbf{X} - n \left( \frac{1}{n} \mathbf{X}^\top \mathbf{1} \right) \left( \frac{1}{n} \mathbf{X}^\top \mathbf{1} \right)^\top \right\} \\ &= \frac{1}{n-1} \left( \mathbf{X}^\top \mathbf{X} - \frac{1}{n} \mathbf{X}^\top \mathbf{1} \mathbf{1}^\top \mathbf{X} \right) = \frac{1}{n-1} \mathbf{X}^\top \mathbf{C} \mathbf{X} \end{aligned}$$

con  $\mathbf{C} = \mathbf{I}_n - \frac{1}{n} \mathbf{1} \mathbf{1}^\top$  la matriz de centrado. Es sencillo mostrar que

$$\mathbf{C}^\top = \mathbf{C}, \quad \mathbf{C}^2 = \mathbf{C},$$

es decir  $\mathbf{C}$  es matriz de proyección. Esto permite mostrar el siguiente resultado.

PROPIEDAD 1.55. La matriz de covarianza  $\mathbf{S}$ , es semidefinida positiva.

DEMOSTRACIÓN. Sea  $\mathbf{a} \in \mathbb{R}^p$ , vector no nulo. Tenemos que,

$$\begin{aligned} \mathbf{a}^\top \mathbf{S} \mathbf{a} &= \frac{1}{n-1} \mathbf{a}^\top \mathbf{X}^\top \mathbf{C} \mathbf{X} \mathbf{a} = \frac{1}{n-1} \mathbf{a}^\top \mathbf{X}^\top \mathbf{C}^2 \mathbf{X} \mathbf{a} \\ &= \frac{1}{n-1} \mathbf{u}^\top \mathbf{u} \geq 0, \quad \mathbf{u} = \mathbf{C} \mathbf{X} \mathbf{a}, \end{aligned}$$

es decir,  $\mathbf{S}$  es matriz semidefinida positiva.<sup>5</sup> □

Considere la siguiente transformación:

$$\mathbf{y}_i = \mathbf{A} \mathbf{x}_i + \mathbf{b}, \quad i = 1, \dots, n.$$

Entonces,  $\bar{\mathbf{y}} = \mathbf{A} \bar{\mathbf{x}} + \mathbf{b}$ , mientras que

$$\mathbf{y}_i - \bar{\mathbf{y}} = \mathbf{A} \mathbf{x}_i + \mathbf{b} - \mathbf{A} \bar{\mathbf{x}} - \mathbf{b} = \mathbf{A}(\mathbf{x}_i - \bar{\mathbf{x}}).$$

De este modo,

$$\begin{aligned} \mathbf{S}_y &= \frac{1}{n-1} \sum_{i=1}^n (\mathbf{y}_i - \bar{\mathbf{y}})(\mathbf{y}_i - \bar{\mathbf{y}})^\top = \frac{1}{n-1} \sum_{i=1}^n \mathbf{A}(\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^\top \mathbf{A}^\top \\ &= \frac{1}{n-1} \mathbf{A} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^\top \mathbf{A}^\top = \mathbf{A} \mathbf{S}_x \mathbf{A}^\top. \end{aligned}$$

En particular, para la transformación (de Mahalanobis),

$$\mathbf{z}_i = \mathbf{S}^{-1/2}(\mathbf{x}_i - \bar{\mathbf{x}}), \quad i = 1, \dots, n,$$

donde  $\mathbf{S} = \mathbf{S}^{1/2} \mathbf{S}^{1/2}$  con  $\mathbf{S}^{1/2}$  un factor raíz cuadrada de  $\mathbf{S}$ . Entonces, sigue que

$$\bar{\mathbf{z}} = \mathbf{0}, \quad \text{y} \quad \mathbf{S}_z = \mathbf{I}_p.$$

DEFINICIÓN 1.56 (Distancia de Mahalanobis). Considere una muestra de  $n$  observaciones  $\mathbf{x}_1, \dots, \mathbf{x}_n$  de este modo, la distancia de Mahalanobis es dada por

$$D_i = \{(\mathbf{x}_i - \bar{\mathbf{x}})^\top \mathbf{S}^{-1}(\mathbf{x}_i - \bar{\mathbf{x}})\}^{1/2}, \quad i = 1, \dots, n,$$

como la distancia de la observación  $i$ -ésima hacia el “centro” de los datos,  $\bar{\mathbf{x}}$  ponderada por la matriz de covarianza.

Sea

$$g_{ij} = (\mathbf{x}_i - \bar{\mathbf{x}})^\top \mathbf{S}^{-1}(\mathbf{x}_j - \bar{\mathbf{x}}), \quad i, j = 1, \dots, n.$$

lo que permite definir medidas de sesgo y curtosis multivariadas (Mardia, 1970), dadas por

$$b_{1p} = \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n g_{ij}^3, \quad b_{2p} = \frac{1}{n} \sum_{i=1}^n g_{ii}^2,$$

respectivamente. Las cantidades anteriores llevan a un test para evaluar la normalidad multivariada (ver Mardia, 1974).

EJEMPLO 1.57. El conjunto de datos de flores Iris (Fisher, 1936), corresponden a 150 mediciones (en centímetros) del largo y ancho de los sépalos y largo y ancho de los pétalos para flores iris de las especies Setosa, Versicolor y Virginica. Los siguientes comandos en R permiten obtener el diagrama de dispersión así como algunas estadísticas de resumen para los datos de Iris

<sup>5</sup> $\mathbf{S}$  será definida positiva si  $n \geq p + 1$ .

```

# datos Iris
> iris
  Sepal.Length Sepal.Width Petal.Length Petal.Width Species
1           5.1           3.5           1.4           0.2   setosa
2           4.9           3.0           1.4           0.2   setosa
3           4.7           3.2           1.3           0.2   setosa
...
149          6.2           3.4           5.4           2.3 virginica
150          5.9           3.0           5.1           1.8 virginica

> x <- iris[,1:4] # solamente variables numéricas
> pairs(x, col = iris$Species) # Fig.3

```

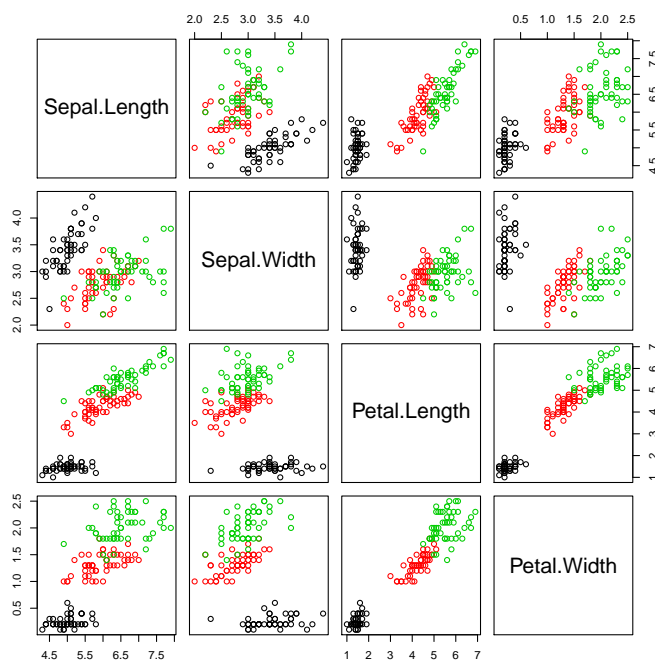


Figura 3. Gráficos de dispersión para los datos de Iris, según variedades Setosa (negro), Versicolor (rojo) y Virginica (verde).

El gráfico de dispersión desplegado en la Figura 3 revela una separación evidente en dos grupos (Setosa versus Versicolor y Virginica). Note los siguientes comandos:

```

# Cálculo de estadísticas de resumen multivariadas
> xbar <- apply(x, 2, mean)
> S <- cov(x)
> R <- cor(x)
> D2 <- mahalnobis(x, xbar, S)
> kurtosis <- mean(D2)

```

En la línea de comandos de R podemos escribir `xbar`, `R` y `kurtosis` para obtener, el vector de medias, la matriz de correlación y el coeficiente de curtosis muestrales, dados por:

$$\bar{\mathbf{x}} = \begin{pmatrix} 5.8433 \\ 3.0573 \\ 3.7580 \\ 1.1993 \end{pmatrix}, \quad \mathbf{R} = \begin{pmatrix} 1.0000 & -0.1176 & 0.8718 & 0.8179 \\ -0.1176 & 1.0000 & -0.4284 & -0.3661 \\ 0.8718 & -0.4284 & 1.0000 & 0.9629 \\ 0.8179 & -0.3661 & 0.9629 & 1.0000 \end{pmatrix},$$

y  $b_{2p} = 3.9733$ , respectivamente.

### 1.5. Regresión lineal simple

Ahora estamos enfocados en situaciones tales que la variable  $x$  permite predecir o explicar la respuesta  $y$ . En regresión lineal tenemos el modelo,

$$y_i = \alpha + \beta x_i + \epsilon_i, \quad i = 1, \dots, n. \quad (1.27)$$

El objetivo es, basado en el conjunto de datos pareados,  $(x_1, y_1), \dots, (x_n, y_n)$  determinar  $\alpha$  y  $\beta$  tal que produzcan el mejor ajuste. Utilizaremos el *método de mínimos cuadrados ordinarios* (OLS) definido como:

$$\min_{\boldsymbol{\theta}} S(\boldsymbol{\theta}),$$

con  $\boldsymbol{\theta} = (\alpha, \beta)^\top$  y

$$S(\boldsymbol{\theta}) = \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2 = \sum_{i=1}^n \epsilon_i^2.$$

OBSERVACIÓN 1.58. OLS minimiza las distancias *verticales* a la recta de regresión. Es decir, esto refleja que los  $x_i$ 's están *fijos* (o bien que se asumen conocidos).<sup>6</sup>

La función  $S(\boldsymbol{\theta})$  también es conocida como suma de cuadrados de los errores. De este modo, debemos determinar  $\boldsymbol{\theta} = (\alpha, \beta)^\top$ , mediante resolver las condiciones de primer orden,

$$\begin{aligned} \frac{\partial S(\boldsymbol{\theta})}{\partial \alpha} &= -2 \sum_{i=1}^n (y_i - \alpha - \beta x_i) = 0, \\ \frac{\partial S(\boldsymbol{\theta})}{\partial \beta} &= -2 \sum_{i=1}^n x_i (y_i - \alpha - \beta x_i) = 0, \end{aligned}$$

esto lleva a las *ecuaciones normales*:

$$\begin{aligned} \sum_{i=1}^n (y_i - \hat{\alpha} - \hat{\beta} x_i) &= \sum_{i=1}^n y_i - n\hat{\alpha} - \hat{\beta} \sum_{i=1}^n x_i = 0, \\ \sum_{i=1}^n x_i (y_i - \hat{\alpha} - \hat{\beta} x_i) &= \sum_{i=1}^n x_i y_i - \hat{\alpha} \sum_{i=1}^n x_i - \hat{\beta} \sum_{i=1}^n x_i^2 = 0. \end{aligned}$$

Multiplicando la primera ecuación por  $n^{-1}$  y resolviendo para  $\hat{\alpha}$ , obtenemos

$$\hat{\alpha} = \bar{y} - \hat{\beta} \bar{x}.$$

<sup>6</sup>Una alternativa es usar mínimos cuadrados totales o modelos con errores en las variables.

Substituyendo  $\hat{\alpha}$  en la segunda ecuación, tenemos

$$\begin{aligned} \sum_{i=1}^n x_i y_i - (\bar{y} - \hat{\beta}\bar{x}) \sum_{i=1}^n x_i - \hat{\beta} \sum_{i=1}^n x_i^2 &= 0 \\ \sum_{i=1}^n x_i y_i - n\bar{x}\bar{y} + \hat{\beta}n\bar{x}^2 - \hat{\beta} \sum_{i=1}^n x_i^2 &= 0 \\ \sum_{i=1}^n x_i y_i - n\bar{x}\bar{y} - \hat{\beta} \left( \sum_{i=1}^n x_i^2 - n\bar{x}^2 \right) &= 0 \\ \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) - \hat{\beta} \sum_{i=1}^n (x_i - \bar{x})^2 &= 0. \end{aligned}$$

Lo que lleva a

$$\hat{\beta} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\text{cov}(\mathbf{x}, \mathbf{y})}{\text{var}(\mathbf{x})}.$$

De este modo, la *recta de regresión* asume la forma:

$$\hat{y}_i = \hat{\alpha} + \hat{\beta} x_i, \quad i = 1, \dots, n,$$

y llamamos a  $\hat{y}_i$  el valor “predicho” o “ajuste” para  $x_i$ . Se define

$$e_i = y_i - \hat{y}_i = y_i - \hat{\alpha} - \hat{\beta} x_i, \quad i = 1, \dots, n,$$

como el  $i$ -ésimo *residuo*, mientras que una medida de variabilidad es dada por:

$$s^2 = \frac{1}{n-2} \sum_{i=1}^n e_i^2 = \frac{1}{n-2} \sum_{i=1}^n (y_i - \hat{\alpha} - \hat{\beta} x_i)^2 = \frac{1}{n-2} S(\hat{\boldsymbol{\theta}}),$$

con  $\hat{\boldsymbol{\theta}} = (\hat{\alpha}, \hat{\beta})^\top$ . Debemos resaltar que, el promedio de los valores predichos  $\hat{y}_1, \dots, \hat{y}_n$ , asume la forma

$$\begin{aligned} \frac{1}{n} \sum_{i=1}^n \hat{y}_i &= \frac{1}{n} \sum_{i=1}^n (\hat{\alpha} + \hat{\beta} x_i) = \hat{\alpha} + \hat{\beta} \bar{x} \\ &= (\bar{y} - \hat{\beta} \bar{x}) + \hat{\beta} \bar{x} = \bar{y}. \end{aligned}$$

Haciendo  $R = \text{cor}(\mathbf{x}, \mathbf{y})$ , sigue que

$$\hat{y}_i - \bar{y} = \hat{\alpha} + \hat{\beta} x_i - \bar{y} = \hat{\beta} (x_i - \bar{x}) = R \frac{s_y}{s_x} (x_i - \bar{x}),$$

es decir,

$$(\hat{y}_i - \bar{y})^2 = R^2 \frac{s_y^2}{s_x^2} (x_i - \bar{x})^2.$$

Lo que nos lleva a escribir,

$$\sum_{i=1}^n (\hat{y}_i - \bar{y})^2 = R^2 \frac{s_y^2}{s_x^2} \sum_{i=1}^n (x_i - \bar{x})^2 = R^2 \frac{s_y^2}{s_x^2} s_x^2 = R^2 s_y^2 = R^2 \sum_{i=1}^n (y_i - \bar{y})^2.$$

A partir de esta ecuación, sigue que

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = \frac{s_{\text{AJUSTE}}^2}{s_{\text{DATOS}}^2},$$

que se denomina *coeficiente de determinación*. Usando además que

$$y_i - \bar{y} = (y_i - \hat{y}_i) + (\hat{y}_i - \bar{y}),$$

podemos mostrar que

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2,$$

es decir,

$$s_{\text{DATOS}}^2 = s_{\text{RESIDUOS}}^2 + s_{\text{AJUSTE}}^2.$$

Como  $s_{\text{RESIDUOS}}^2 = S(\hat{\theta})$ , tenemos que  $s_{\text{AJUSTE}}^2 = R^2 s_{\text{DATOS}}^2$ . Luego, sigue que:

$$s_{\text{RESIDUOS}}^2 = (1 - R^2) s_{\text{DATOS}}^2.$$

Esto permite interpretar  $R^2$  como la proporción de varianza de los datos que puede ser explicada por el ajuste. En efecto,  $0 \leq R^2 \leq 1$  permite medir la calidad (o bondad) del ajuste.

**EJEMPLO 1.59.** Debemos ser precavidos al llevar un análisis de regresión y confiar de medidas tales como el  $R^2$  para evaluar la calidad del ajuste. Para notar este tipo de situaciones, considere los datos introducidos por [Anscombe \(1973\)](#). Este corresponde a cuatro conjunto de datos con 11 observaciones que aunque son bastante diferentes tienen estadísticas de resumen idénticas (promedio, varianza, correlación, coeficientes de regresión, etc.). En efecto, considere el siguiente gráfico

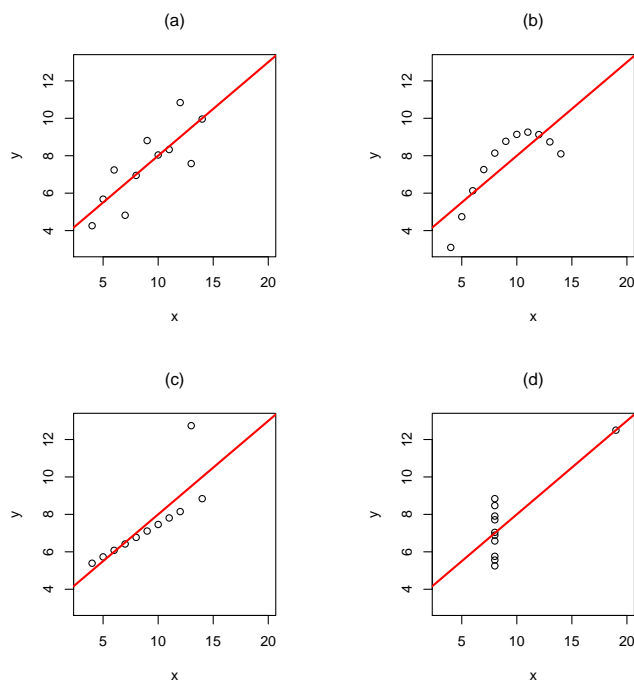


Figura 4. Cuarteto de regresiones idénticas de [Anscombe \(1973\)](#).

Por ejemplo, en la Figura 4(b), los datos presentan una tendencia cuadrática, mientras que en los Paneles (c) y (d) se aprecia el efecto de observaciones atípicas sobre la recta de regresión. Más aún, eliminando la observación extrema en el conjunto de datos en la Figura 4(d), la regresión deja de tener sentido. Para obtener los resultados del ajuste mediante regresión por mínimos cuadrados podemos considerar los siguientes comandos de R

```
# datos de Anscombe
> anscombe
  x1 x2 x3 x4   y1   y2   y3   y4
1  10 10 10  8  8.04 9.14  7.46  6.58
2   8  8  8  8  6.95 8.14  6.77  5.76
3  13 13 13  8  7.58 8.74 12.74  7.71
...
10  7  7  7  8  4.82 7.26  6.42  7.91
11  5  5  5  8  5.68 4.74  5.73  6.89

# Ajuste mediante OLS (para cada uno de los modelos)
> fm1 <- lm(y1 ~ x1, data = anscombe)
> fm2 <- lm(y2 ~ x2, data = anscombe)
> fm3 <- lm(y3 ~ x3, data = anscombe)
> fm4 <- lm(y4 ~ x4, data = anscombe)

# Figura 4.a (otros paneles son análogos)
> par(pty = "s")
> plot(y1 ~ x1, data = anscombe, xlim = c(4,20),
+      ylim = c(3,13), xlab = "x", ylab = "y")
> abline(coef(fm1), col = "red", lwd = 2) # línea en rojo

# Salida de resultados:
> summary(fm1)
Call:
lm(formula = y1 ~ x1, data = anscombe)

Residuals:
    Min       1Q   Median       3Q      Max
-1.92127 -0.45577 -0.04136  0.70941  1.83882

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)   3.0001     1.1247   2.667  0.02573 *
x1             0.5001     0.1179   4.241  0.00217 **

Residual standard error: 1.237 on 9 degrees of freedom
Multiple R-squared:  0.6665, Adjusted R-squared:  0.6295
F-statistic: 17.99 on 1 and 9 DF, p-value: 0.00217

# Almacena coeficientes, residuos y valores predichos
> cf <- coef(fm1)
> res <- resid(fm1)
> fit <- fitted(lm1)
```



```
# Figura 5.a (otros paneles son análogos)
> par(pty = "s")
> plot(fit, res, xlab="Valores predichos", ylab="Residuos")
> abline(h = 0, lty = 2, col = "gray", lwd = 2) # línea gris
```

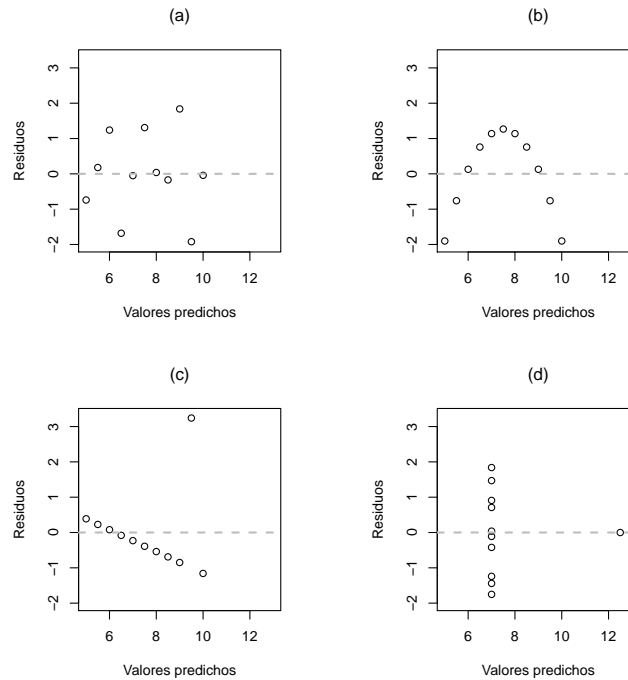


Figura 5. Gráfico de residuos para el cuarteto de regresiones idénticas de [Anscombe \(1973\)](#).

Para el modelo en Ecuación (1.27), es posible mostrar que:

$$\sum_{i=1}^n e_i = 0, \quad y \quad \sum_{i=1}^n e_i \hat{y}_i = 0.$$

De este modo, el gráfico de dispersión de residuos contra valores predichos dado en la Figura 5 no debería presentar algún tipo de comportamiento sistemático. Por tanto, en el Panel en (a) esperado que se debería notar



## Bibliografía

- Anscombe, F.J. (1973) Graphs in statistical analysis. *The American Statistician* **27**, 17-21.
- Barlow, J.L. (1993). Numerical aspects of solving linear least squares problems. En: *Handbook of Statistics, Vol. 9*, C.R. Rao (Ed.). Elsevier, pp. 303-373.
- Bolfarine, H., Sandoval, M.C. (2001). *Introdução à Inferência Estatística*. Sociedade Brasileira de Matemática, Rio de Janeiro.
- Casella, G., Berger, R.L. (2002). *Statistical Inference (2nd Ed.)*. Duxbury, Pacific Grove.
- Chan, T.F., Lewis, J.G. (1979). Computing standard deviations: Accuracy. *Communications of the Association for Computing Machinery* **22**, 526-531.
- Chan, T.F., Golub, G.H., LeVeque, R.J. (1983). Algorithms for computing the sample variance: Analysis and recommendations. *The American Statistician* **37**, 242-247.
- Clarke, M.R.B. (1971). Algorithm AS 41: Updating the sample mean and dispersion matrix. *Applied Statistics* **20**, 206-209.
- Frery, A.C., Cribari-Neto, F. (2005). *Elementos de Estatística Computacional Usando Plataformas de Software Livre/Gratuito*. IMPA, Rio de Janeiro.
- Fisher, R.A. (1936). The use of multiple measurements in taxonomic problems. *Annals of Eugenics* **7**, 179-188.
- Galbiati, J. (2012). *Tablas de Probabilidad (8a Ed.)*. Instituto de Estadística, Pontificia Universidad Católica de Valparaíso, Chile.
- Grossman, S.I., Turner, J.E. (1974). *Mathematics for the Biological Sciences*. MacMillan Publishing, New York.
- Jambu, M. (1991). *Exploratory and Multivariate Data Analysis*. Academic Press, Boston.
- Keeling, K.B., Pavur, R.J. (2007). A comparative study of the reliability of nine statistical software packages. *Computational Statistics & Data Analysis* **51**, 3811-3831.
- Knuth, D.E. (1997). *The Art of Computer Programming: Vol. 1, Fundamental Algorithms*. Addison-Wesley, Massachusetts.
- Mardia, K.V. (1970). Measures of multivariate skewness and kurtosis with applications. *Biometrika* **57**, 519-530.
- Mardia, K.V. (1974). Application of some measures of multivariate skewness and kurtosis in testing normality and robustness studies. *Sankhyā, Series B* **36**, 115-128.
- McCullough, B.D., Wilson, B. (1999). On the accuracy of statistical procedures in Microsoft Excel 97. *Computational Statistics & Data Analysis* **31**, 27-37.
- McCullough, B.D., Wilson, B. (2002). On the accuracy of statistical procedures in Microsoft Excel 2000 and Excel XP *Computational Statistics & Data Analysis*

- 40, 713-721.
- McCullough, B.D., Wilson, B. (2005). On the accuracy of statistical procedures in Microsoft Excel 2003 *Computational Statistics & Data Analysis* **49**, 1244-1252.
- Mood, A.M., Graybill, F.A., Boes, D.C. (1974). *Introduction to the Theory of Statistics (3rd Ed.)*. McGraw-Hill, New York.
- Osorio, F. (2015). MVT: Estimation and testing for the multivariate  $t$ -distribution. R package version 0.3 URL: [CRAN.R-project.org/package=MVT](http://CRAN.R-project.org/package=MVT)
- Osorio, F. (2018). heavy: Robust estimation using heavy-tailed distributions. R package version 0.38.19. URL: [CRAN.R-project.org/package=heavy](http://CRAN.R-project.org/package=heavy)
- Panaretos, V.M. (2016). *Statistics for Mathematicians: A Rigorous First Course*. Birkhäuser, Laussane.
- Pébay, P., Terriberry, T.B., Kolla, H., Bennett, J. (2016). Numerically stable, scalable formulas for parallel and online computation of higher order multivariate central moments with arbitrary weights. *Computational Statistics* **31**, 1305-1325.
- Press, W.H., Teukolsky, S.A., Vetterling, W.T., Flannery, B.P. (1992). *Numerical Recipes in C: The Art of Scientific Computing*. Cambridge University Press, Cambridge.
- R Core Team (2019). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria.  
URL: <http://www.R-project.org>
- Thisted, R.A. (1988). *Elements of Statistical Computing*. Champan & Hall, Boca Raton.
- Tukey, J.W. (1977). *Exploratory Data Analysis*. Addison-Wesley, Massachusetts.
- Venables, W.N., Ripley, B.D. (1994). *Modern Applied Statistics with S-Plus*. Springer, New York.
- Wasserman, L. (2004). *All of Statistics: A Concise Course in Statistical Inference*. Springer, New York.
- Welford, B.P. (1962). Note on a method for calculating corrected sums of squares and products. *Technometrics* **4**, 419-420.
- West, D.H.D. (1979). Updating mean and variances estimates: An improved method. *Communications of the Association for Computing Machinery* **22**, 532-535.