



1. Variables estadísticas. Definiciones y clasificación

Población: Conjunto de individuos que son objeto de un estudio


Muestra: Subconjunto de la población

Unidad estadística: Cada uno de los elementos de la población: (Individuo)

Caracteres: Cada individuo podemos estudiarlo según uno o varios caracteres.

Modalidades: las respuestas posibles de estos caracteres.

Variables estadísticas y clasificación:



2. Distribuciones de frecuencias. Representaciones gráficas

Frecuencia absoluta: el nº de individuos que pertenecen a dicha modalidad (A_i): n_i i=1÷n

Frecuencia relativa: cociente entre $\frac{n_i}{n} \rightarrow$ frec. absoluta. $n \rightarrow$ nº total de datos. $f_i = \frac{n_i}{n}$

$$\sum_{i=1}^n n_i = n \quad \sum_{i=1}^n f_i = 1$$

Ejemplo carácter cuantitativo discreto:

	n _i	f _i	P _i	f. abs. acum.	f. rel. acum.
0	10	10/25 = 0,4	40%	10	0,4
1	9	9/25 = 0,36	36%	19	0,76
2	6	6/25 = 0,24	24%	25	1
	25	1	100%		

$$\sum n_i = 10 + 9 + 6 = 25 = n$$

$$\sum f_i = 0,4 + 0,36 + 0,24 = 1$$

Ejemplo carácter cuantitativo continuo:

x _i	marca obs	n _i	f _i	P _i	f. abs. acum.	f. rel. acum.
[0,2)	1	3	3/25 = 0,12	12%	3	0,12
[2,4)	3	4	4/25 = 0,16	16%	7	0,28
[4,6)	5	10	10/25 = 0,4	40%	17	0,68
[6,8)	7	7	7/25 = 0,28	28%	24	0,96
[8,10]	9	1	1/25 = 0,04	4%	25	1
		25	1	100%		

Representaciones gráficas:

Gráfico circular o de sectores: \Rightarrow frec. relativa $\times 360^\circ$ // $f_{relat} \times 180^\circ$ (Semicírculo)

	n _i	f _i	P _i	f. abs. acum.	f. rel. acum.	ángulo
0	10	10/25 = 0,4	40%	10	0,4	144°
1	9	9/25 = 0,36	36%	19	0,76	129,6°
2	6	6/25 = 0,24	24%	25	1	86,4°
	25	1	100%			360°








Diagrama de barras o gráfico de Pareto:



Histograma y polígono de frecuencias:




3. Parámetros estadísticos:


Parámetros estadísticos de centralización:

Moda: el valor de la variable que presenta la mayor frecuencia absoluta.

Mediana: datos ordenados de menor a mayor, es el valor que divide la muestra en dos partes con el mismo número de elementos.



$\frac{n}{2} + 0,5$
posición de la Mediana



$\frac{n}{2}, \frac{n}{2} + 1$
las posiciones de los dos valores

Media o valor medio:

$\bar{x} = \frac{\sum x_i}{n} = \frac{\sum x_i \cdot n_i}{n}$ (with n_i circled and labeled f. abs)

$\bar{x} = \sum f_i \cdot x_i$ (with f_i circled and labeled f. relat.)

Propiedades:

1, 3, 6, 8 $\xrightarrow{+2}$ 3, 5, 8, 10
 $\bar{x} = \frac{1+3+6+8}{4} = 4,5$ $\bar{x} = \frac{3+5+8+10}{4} = 6,5$

1) x y x' relacionadas con una transf. lineal \Rightarrow sus medias están relacionadas con la misma transf. lin.

2) la media de la diferencia de una variable a su media es cero.

Momento no centrado de orden r:

$\alpha_r = \frac{\sum n_i \cdot x_i^r}{n}$

Parámetros estadísticos de dispersión:

Desviación media:

$D.M(x) = \frac{\sum_{i=1}^k n_i \cdot |x_i - \bar{x}|}{n}$





$$V(ax) = a^2 V(x)$$

$$V(x+b) = V(x)$$

Varianza:

$$V(x) = \frac{\sum n_i (x_i - \bar{x})^2}{n}$$

$$x' = \frac{x-b}{a}$$

$$V(x') = \frac{1}{a^2} V(x)$$

Desviación típica:

$$s_x = \sqrt{\frac{\sum n_i (x_i - \bar{x})^2}{n}}$$

$$\left[\begin{array}{l} 1 \quad 4 \quad 7 \\ \bar{x} = \frac{1+4+7}{3} = 4 \\ \rightarrow x' = \frac{x-1}{2} \\ 0, 1,5, 3 \\ \bar{x} = \frac{1,5+3}{3} = 1,5 \end{array} \right.$$

$$V(x) = \frac{(1-4)^2 + (4-4)^2 + (7-4)^2}{3} = 6$$

$$V(x') = \frac{(0-1,5)^2 + (1,5-1,5)^2 + (3-1,5)^2}{3} = 1,5$$

$$V(x') = \frac{1}{2^2} V(x) = \frac{1}{4} \cdot 6 = 1,5$$

Momento centrado de orden r:

$$\mu_r = \frac{\sum n_i (x_i - \bar{x})^r}{n}$$

$$\mu_r \quad r=2 \Rightarrow \mu_2 = \text{Varianza}$$

Cálculo de la varianza:

$$V(x) = \alpha_2 - \alpha_1^2 = \alpha_2 - \bar{x}^2$$

$$V(x) = \frac{1}{n} \sum n_i (x_i - \bar{x})^2 = \frac{1}{n} \sum n_i (x_i^2 - 2x_i \bar{x} + \bar{x}^2) = \frac{1}{n} (\sum n_i x_i^2 - 2\bar{x} \sum n_i x_i + \bar{x}^2 \sum n_i)$$

$$= \frac{1}{n} \sum n_i x_i^2 - 2\bar{x}^2 + \bar{x}^2 = \frac{1}{n} \sum n_i x_i^2 - \bar{x}^2 = \alpha_2 - \alpha_1^2$$

Coefficiente de variación:

$$C.V = v = \frac{s_x}{|\bar{x}|}$$

Si C.V es pequeño \Rightarrow mejor representará la media al conjunto de datos.

Características de forma:

Si distribución simétrica $\Rightarrow \mu_r$ de orden impar son 0.

$$\frac{\sum n_i (x_i - \bar{x})^r}{n}$$

Fisher \rightarrow coeficiente asimetría: $\gamma_1 = \frac{\mu_3}{s^3}$

Si distrib. simétrica $\Rightarrow \mu_3 = 0 \Rightarrow \gamma_1 = 0$

\rightarrow Coeficiente de curtosis:

$$\gamma_2 = \frac{\mu_4}{s^4} - 3$$





Ejemplos:

Ejercicio 1.1. Dada la siguiente distribución de frecuencias de variable discreta, calcúlese: a) mediana, b) moda, c) media, d) varianza y desviación típica y e) porcentaje de datos que pertenecen al intervalo $(\bar{x} - s, \bar{x} + s)$.

x_i	47	48	49	50	51	52	53	
n_i	1	3	2	8	3	2	1	$n=20$

x_i	n_i	$n_i \cdot x_i$	$x_i - \bar{x}$	$(x_i - \bar{x})^2$	$n_i(x_i - \bar{x})^2$	n_i acum.
47	1	47	-3	9	9	
48	3	144	-2	4	12	
49	2	98	-1	1	2	
50	8	400	0	0	0	
51	3	153	1	1	3	
52	2	104	2	4	8	
53	1	53	3	9	9	
	20	999			43	

c) $\bar{x} = \frac{\sum n_i \cdot x_i}{n} = \frac{999}{20} = 49,95 \approx 50$

b) $H_0 = 50$

a) $Me \rightarrow \frac{n}{2} = \frac{20}{2} = 10$ posiciones
 $Me = \frac{50+50}{2} = 50$

d) $s^2 = \frac{\sum n_i(x_i - \bar{x})^2}{n} = \frac{43}{20} = 2,15$

$s = \sqrt{2,15} = 1,466$

c.v. = $\frac{s}{|\bar{x}|} \approx \frac{1,466}{50} = 0,02932$ no presuntan

e) $\bar{x} - s = 49,95 - 1,466 = 48,484$

$\bar{x} + s = 49,95 + 1,466 = 50,966$

los datos que están (48,48 ; 50,966)

Tenemos $\frac{13}{20} \times 100 = 65\%$

Ejercicio 1.2. Sobre la siguiente distribución de frecuencias de variable continua, efectuando un cambio de origen y de escala apropiados, calcúlese: a) media, b) varianza y desviación típica, c) histograma de frecuencias y d) porcentaje de datos en el intervalo $(\bar{x} - s, \bar{x} + s)$. Interpretación estadística de este resultado.

Clases	5-25	25-35	35-45	45-55	55-65	65-85	
n_i	2	4	10	10	3	1	$n=30$

clases	n_i	M.C	$x'_i = \frac{x_i - 10}{5}$	$n \cdot x'_i$	$n \cdot x'^2_i$
[5-25]	2	15	-5	-10	50
[25-35]	4	30	-2	-8	16
[35-45]	10	40	0	0	0
[45-55]	10	50	2	20	40
[55-65]	3	60	4	12	48
[65-85]	1	75	7	7	49
	30			21	203

a) $\bar{x} = \frac{\sum n_i \cdot x_i}{n} = \frac{2 \cdot 15 + 4 \cdot 30 + 10 \cdot 40 + 10 \cdot 50 + 3 \cdot 60 + 1 \cdot 75}{30} = 43,5$

$\bar{x}' = \frac{21}{30} = 0,7$

$\bar{x}' = \frac{\bar{x} - 40}{5}$


$5\bar{x}' = \bar{x} - 40 \Rightarrow \bar{x} = 5\bar{x}' + 40 = 43,5$

b) $v(x') = \alpha'_2 - \bar{x}'^2 = \frac{203}{30} - (0,7)^2 = 6,27$

$v(x) = v(5x' + 40) = v(5x') = 25 v(x') = 156,75$

$x' = \frac{x-40}{5}$
 $5x' + 40 = x$

$s(x) = \sqrt{156,75} \approx 12,52$



a) $\bar{x} - s = 43,5 - 12,52 = 30,98$

$\bar{x} + s = 43,5 + 12,52 = 56,02$

Clase [45-55] $\Rightarrow 10$
 [35-45] $\Rightarrow 10$ } entras

[25-35] $\Rightarrow 4$
 $\frac{4}{10} \cdot 4 = 1,6$

10 amp $\rightarrow 4$
 (35-30,98) $\rightarrow x$

[55-65] $\Rightarrow 3$

$x = \frac{4 \cdot 4}{10}$

Si sumamos \Rightarrow Total 21,9 sobre 30 $\Rightarrow \frac{21,9}{30} \times 100 \approx 73\%$

$\frac{3}{10} \cdot 1 = 0,3$

10 ampl $\rightarrow 3$
 (56,02-55) $\rightarrow x$ $x = \frac{3 \cdot 1}{10}$





4. Distribución de frecuencias multivariante:

Definición 10.1. Se llama *distribución conjunta de frecuencias* de dos variables X e Y a una tabla en donde se representan los valores observados de cada variable y las frecuencias absolutas de cada par.

X \ Y	Y			
	100°	110°	120°	
1	10	6	4	20
2	8	30	12	50
3	2	9	19	30
	20	45	35	100

$$\sum_i \sum_j n_{ij} = n$$

$$\sum_i n_{ij} = n_{.j}$$

5. Distribuciones marginales y condicionadas:

Distribución marginal: la que se obtiene al estudiar esa variable con independencia de las demás

$$n_{i.} = \sum_j n_{ij} \quad n_{.j} = \sum_i n_{ij}$$

X	1	2	3	
	20	50	30	100
	$n_{1.}$	$n_{2.}$	$n_{3.}$	
Y	100°	110°	120°	
	20	45	35	100
	$n_{.1}$	$n_{.2}$	$n_{.3}$	

Distribución condicionada:

Distribución condicionada de Y por X=x a la distribución de frecuencias que se obtiene considerando únicamente las frecuencias X=x

Y condicionada X=2

Y	100°	110°	120°	
	8	30	12	50
Y	100°	110°	120°	
	8/50	30/50	12/50	

X \ Y	Y			
	100°	110°	120°	
1	10	6	4	20
2	8	30	12	50
3	2	9	19	30
	20	45	35	100

$$f(y_i/x_i) = \frac{n_{ij}}{n_{i.}}$$

$$f(x_i/y_j) = \frac{n_{ij}}{n_{.j}}$$

$$f(y_j/x_i) = \frac{f(x_i, y_j)}{f(x_i)}$$

$$f(x_i/y_j) = \frac{f(x_i, y_j)}{f(y_j)}$$

f(X/y=110°)	1	6/45
	2	30/45
	3	9/45

6. Vector de medias. Matriz de varianza y covarianzas:

Vector de medias: de la variable k-dimensional X, $\bar{X} = \begin{pmatrix} \bar{x}_1 \\ \vdots \\ \bar{x}_k \end{pmatrix}$
 $\bar{X} = (2,1, 111,5)$

$$\bar{X} = \frac{1 \cdot 20 + 2 \cdot 50 + 3 \cdot 30}{100} = 2,1$$

$$\bar{Y} = \frac{20 \cdot 100^\circ + 45 \cdot 110^\circ + 125 \cdot 120^\circ}{100} = 111,5^\circ$$

Matriz de varianza y covarianzas:

Covarianza: $\text{Cov}(X,Y) = \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{n}$ $\text{Cov}(X,Y) = \frac{\sum_i n_{ij} (x_i - \bar{x})(y_i - \bar{y})}{n} = \sum_i f_{ij} (x_i - \bar{x})(y_i - \bar{y})$

Matriz de Covarianzas:

Varianza: $S_x^2; S_y^2$

⇓
matriz cuadrada y simétrica

$$C = \begin{pmatrix} S_x^2 & \text{Cov}(X,Y) \\ \text{Cov}(X,Y) & S_y^2 \end{pmatrix}$$

obs: $\text{Cov}(X,Y) = \text{Cov}(Y,X)$

Variable 2-dimensional

$$C = \begin{pmatrix} S_1^2 & S_{12} & S_{13} & \dots & S_{1k} \\ S_{21} & S_2^2 & S_{23} & \dots & \\ S_{31} & S_{32} & S_3^2 & \dots & \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ S_{k1} & \dots & \dots & \dots & S_k^2 \end{pmatrix}$$

Variable k-dimensional





La matriz de covarianzas es siempre SEMIDEFINIDA POSITIVA

Coeficiente de correlación :

$$r = \frac{\text{Cov}(X, Y)}{S_x \cdot S_y} \rightarrow \text{es invariante por cambios de origen y de escala. } r \in [-1, 1]$$

desviación típica X desviación típica Y

$$x' = ax + b \quad y' = cy + d$$

$$r' = \frac{\text{Cov}(x', y')}{S_{x'} \cdot S_{y'}} = \frac{\sum (ax + b - a\bar{x} - b)(cy + d - c\bar{y} - d)}{S_x \cdot S_y \cdot n} = \frac{1}{n} \frac{a \cdot c \sum (x - \bar{x})(y - \bar{y})}{S_x \cdot S_y}$$

$$S_{x'} = a S_x \quad S_{y'} = c S_y$$

$$= r = \frac{\text{Cov}(X, Y)}{S_x \cdot S_y}$$

Ejercicio 1.4. A partir de los datos de la siguiente tabla, referentes a horas trabajadas en un taller y unidades producidas, calcúlese el vector de medias y el coeficiente de correlación.

x horas trabajadas	88	80	83	84	78	62
y unidades producidas	300	302	316	330	300	250
x horas trabajadas	82	85	80	84	80	62
y unidades producidas	300	340	315	330	310	243

x	y	x - x̄	y - ȳ	(x - x̄)²	(y - ȳ)²	(x - x̄)(y - ȳ)
88	300	9	-3	81	9	-27
80	302	1	-1	1	1	-1
83	316	4	13	16	169	52
84	330	5	27	25	729	135
78	300	-1	-3	1	9	3
62	250	-17	-53	289	2809	901
82	300	3	-3	9	9	-9
85	340	6	37	36	1369	222
80	315	1	12	1	144	12
84	330	5	27	25	729	135
80	310	1	7	1	49	7
62	243	-17	-60	289	3600	1020
948	3636	0	0	774	9626	2450

$$\bar{x} = \frac{\sum x_i}{n} = \frac{88+80+\dots+62}{12} = \frac{948}{12} = 79$$

$$\bar{y} = \frac{\sum y_i}{n} = \frac{300+302+\dots+243}{12} = \frac{3636}{12} = 303$$

$$S_x^2 = \frac{\sum (x_i - \bar{x})^2}{n} = \frac{774}{12} = 64,5 \Rightarrow S_x = \sqrt{64,5} = 8,03$$

$$S_y^2 = \frac{\sum (y_i - \bar{y})^2}{n} = \frac{9626}{12} = 802,166 \Rightarrow S_y = \sqrt{802,166} = 28,3224$$

$$\text{Cov}(X, Y) = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{n} = \frac{2450}{12} = 204,166$$

$$r = \frac{\text{Cov}(X, Y)}{S_x \cdot S_y} = \frac{204,166}{8,03 \cdot 28,3224} = 0,8977$$

matriz covarianzas

$$C = \begin{pmatrix} S_x^2 & \text{Cov}(X, Y) \\ \text{Cov}(Y, X) & S_y^2 \end{pmatrix}$$

$$= \begin{pmatrix} 64,5 & 204,166 \\ 204,166 & 802,166 \end{pmatrix}$$

