

## Formulario de Estadística I

**Tema 1** Consideramos una muestra de tamaño  $n$  de una variable  $X$ . Sean  $x_1, x_2, \dots, x_k, k \leq n$ , los diferentes valores que ha tomado esta variable sobre los  $n$  individuos de la muestra. Si  $X$  es cuantitativa o categórica ordinal, supondremos que tenemos los valores ordenados de manera que  $x_1 < x_2 < \dots < x_k$ .

- Se denota por  $n_i$  la **frecuencia absoluta** del valor  $x_i$ . Se cumple que  $\sum_{i=1}^k n_i = n$ .
- Se define la **frecuencia relativa** del valor  $x_i$  como  $f_i = n_i/n$ . Se verifica que  $\sum_{i=1}^k f_i = 1$ .
- Se define la **frecuencia absoluta acumulada** del valor  $x_i$  como  $N_i = \sum_{j=1}^i n_j$ .
- Se define la **frecuencia relativa acumulada** del valor  $x_i$  como  $F_i = N_i/n$ . Se cumple que  $F_i = \sum_{j=1}^i f_j$ .
- Cuando los datos están agrupados en intervalos de clase, llamamos  $l_{i-1}$  y  $l_i$  a los **extremos inferior y superior**, respectivamente, del intervalo  $i$ -ésimo.
- La **longitud** o **amplitud** del intervalo  $i$ -ésimo es  $L_i = l_i - l_{i-1}$ .
- La **marca de clase** del intervalo  $i$ -ésimo es  $x_i = \frac{l_i + l_{i-1}}{2}$ .

**Tema 2** Las fórmulas de las siguientes medidas numéricas están expresadas considerando la muestra original, es decir, los  $n$  valores observados para  $X$  son  $x_1, x_2, \dots, x_n$ . La muestra ordenada se denota por  $x_{(1)}, x_{(2)}, \dots, x_{(n)}$ .

### Medidas de centralización o de tendencia central:

- Media aritmética:  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ .
- Mediana:

$$Me = \begin{cases} \frac{1}{2}(x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)}), & \text{si } n \text{ es par,} \\ x_{(\frac{n+1}{2})}, & \text{si } n \text{ es impar.} \end{cases}$$

- Moda: La moda es el valor  $x_i$  que presenta una mayor frecuencia absoluta (o relativa).

### Medidas de posición:

- Cuartiles:  $Q_k = x_{(k(n+1)/4)}$  para  $k = 1, 2, 3$ .
- Percentiles:  $P_k = x_{(k(n+1)/100)}$  para  $k = 1, 2, \dots, 99$ .

### Medidas de dispersión o de variabilidad:

- Rango o amplitud:  $R = x_{max} - x_{min}$ .
- Rango intercuartílico:  $RIC = Q_3 - Q_1$ .
- Varianza muestral:  $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} [\sum_{i=1}^n x_i^2 - n\bar{x}^2]$ .
- Desviación típica (o estándar) muestral:  $\hat{\sigma} = \sqrt{\hat{\sigma}^2}$ .
- Cuasivarianza muestral:  $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n-1} [\sum_{i=1}^n x_i^2 - n\bar{x}^2]$ .
- Cuasidesviación típica muestral:  $s = \sqrt{s^2}$ .
- Coeficiente de variación de Pearson:  $CV = s/|\bar{x}|$ .

**Tema 3** Sea  $(X, Y)$  una variable bidimensional que puede tomar  $k \times m$  pares de valores diferentes  $(x_i, y_j)$ ,  $i = 1, \dots, k, j = 1, \dots, m$ , sobre los  $n$  individuos de una muestra. Supondremos que los datos están ordenados de manera que  $x_1 < x_2 < \dots < x_k, y_1 < y_2 < \dots < y_m$ , a menos que las variables sean categóricas nominales.

Tabla 1: Estructura de la tabla de doble entrada / tabla de contingencias

$X \setminus Y$	$y_1$	$y_2$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x_1$	$n_{11}$	$n_{12}$	$\dots$	$n_{1j}$	$\dots$	$n_{1m}$	$n_{1\bullet}$
$x_2$	$n_{21}$	$n_{22}$	$\dots$	$n_{2j}$	$\dots$	$n_{2m}$	$n_{2\bullet}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$x_i$	$n_{i1}$	$n_{i2}$	$\dots$	$n_{ij}$	$\dots$	$n_{im}$	$n_{i\bullet}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$x_k$	$n_{k1}$	$n_{k2}$	$\dots$	$n_{kj}$	$\dots$	$n_{km}$	$n_{k\bullet}$
Total	$n_{\bullet 1}$	$n_{\bullet 2}$	$\dots$	$n_{\bullet j}$	$\dots$	$n_{\bullet m}$	$n_{\bullet\bullet}$

- Se denota por  $n_{ij}$  la **frecuencia absoluta** del par  $(x_i, y_j)$  y  $n = n_{\bullet\bullet}$ .
- Se define la **frecuencia relativa** del par  $(x_i, y_j)$  como  $f_{ij} = n_{ij}/n$ .
- Se define la **frecuencia absoluta marginal** del valor  $x_i$  como  $n_{i\bullet} = \sum_{j=1}^m n_{ij}$ .
- Se define la **frecuencia relativa marginal** del valor  $x_i$  como  $f_{i\bullet} = n_{i\bullet}/n$ .
- Se define la **frecuencia absoluta marginal** del valor  $y_j$  como  $n_{\bullet j} = \sum_{i=1}^k n_{ij}$ .
- Se define la **frecuencia relativa marginal** del valor  $y_j$  como  $f_{\bullet j} = n_{\bullet j}/n$ .

### Características numéricas conjuntas para tablas de doble entrada.

Sean  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  los  $n$  pares de valores observados para  $(X, Y)$ . Entonces:

- Covarianza:

$$s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \frac{1}{n-1} \left[ \sum_{i=1}^n x_i y_i - n\bar{x}\bar{y} \right]$$

- Coeficiente de correlación lineal de Pearson:

$$r_{(x,y)} = \frac{s_{xy}}{s_x s_y}$$

La ecuación de la recta de regresión de  $Y$  sobre  $X$  por el método de los mínimos cuadrados es:

$$\hat{y} = a + bx, \quad \text{donde} \quad b = \frac{s_{xy}}{s_x^2}, \quad a = \bar{y} - b\bar{x}.$$

Se denominan **valores predichos (o ajustados)** a los valores  $\hat{y}_i = a + bx_i$ , para  $i = 1, \dots, n$ , y se llaman **residuos** a  $e_i = y_i - \hat{y}_i$ , para  $i = 1, \dots, n$ . Se cumple que  $\bar{e} = 0$ .

**Tema 4** Sea  $\Omega$  el espacio muestral asociado a cierto experimento aleatorio,  $B_1, \dots, B_k$  una partición de  $\Omega$ , tal que  $P(B_i) \neq 0$  para  $i = 1, \dots, k$  y  $A$  un suceso cualquiera.

- Ley de la probabilidad total:

$$P(A) = P(A \cap B_1) + \dots + P(A \cap B_k) = P(A|B_1)P(B_1) + \dots + P(A|B_k)P(B_k).$$

- Teorema de Bayes:

$$P(B_j|A) = \frac{P(B_j \cap A)}{P(A)} = \frac{P(A|B_j)P(B_j)}{P(A|B_1)P(B_1) + \dots + P(A|B_k)P(B_k)}, \quad \text{para } j = 1, \dots, k.$$

### Esperanza y varianza de una variable aleatoria.

Sea  $X$  una v.a. que toma valores en un conjunto  $S$ . La esperanza y varianza de  $X$  se definen como:

$$E(X) = \begin{cases} \sum_{x \in S} x P(X=x), & \text{si } X \text{ es una v.a. discreta,} \\ \int_S x f(x) dx, & \text{si } X \text{ es una v.a. continua.} \end{cases}$$

$$\text{var}(X) = \begin{cases} \sum_{x \in S} (x - E(X))^2 P(X=x), & \text{si } X \text{ es una v.a. discreta,} \\ \int_S (x - E(X))^2 f(x) dx, & \text{si } X \text{ es una v.a. continua.} \end{cases}$$

### Modelos de probabilidad.

Ley de $X$	Conjunto $S$	Función de probabilidad / densidad	$E(X)$	$\text{var}(X)$
$Ber(p)$	$\{0, 1\}$	$P(X=1) = p, P(X=0) = 1-p$	$p$	$p(1-p)$
$B(n, p)$	$\{0, 1, \dots, n\}$	$P(X=x) = \binom{n}{x} p^x (1-p)^{n-x}$	$np$	$np(1-p)$
$Pois(\lambda)$	$\mathbb{N} \cup \{0\}$	$P(X=x) = e^{-\lambda} \frac{\lambda^x}{x!}$	$\lambda$	$\lambda$
$U(a, b)$	$(a, b)$	$f(x) = \frac{1}{b-a}$	$(a+b)/2$	$(b-a)^2/12$
$exp(\lambda)$	$\mathbb{R}^+$	$f(x) = \lambda e^{-\lambda x}$	$1/\lambda$	$1/\lambda^2$
$N(\mu, \sigma)$	$\mathbb{R}$	$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left\{-\frac{1}{2\sigma^2}(x-\mu)^2\right\}$	$\mu$	$\sigma^2$

**Tema 5** Intervalos de confianza al  $(1 - \alpha) \times 100\%$

- para la media poblacional (suponiendo varianza conocida)  $\left[ \bar{x} \mp z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right]$ ,
- para la proporción poblacional  $\left[ \hat{p} \mp z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \right]$ ,

donde  $z_{\alpha/2}$  es el percentil  $(1 - \alpha/2) \times 100$  de la ley  $N(0, 1)$ .