

## TEMA 9

### CONTRASTES NO PARAMÉTRICOS

#### 9.6. **INTRODUCCIÓN**

- Para no exigir robustez sobre la hipótesis de normalidad de la distribución subyacente, se utilizan técnicas no paramétricas
- Dos situaciones
  - Técnicas No Paramétricas en sentido estricto: estadístico sin referencia a parámetro poblacional
  - Métodos de distribución libre: distribución del estadístico no depende de la de la población
- Utilizan frecuencias y no estadísticos
  - Frecuencia absoluta  $n_i$
  - Frecuencia absoluta acumulada  $N_i$
- Ejemplos
  - Bondad de ajuste (muestra de una determinada población)
  - Independencia entre niveles de dos factores

#### 9.7. **CONTRASTES DE BONDAD DE AJUSTE**

- Objetivo: verificar si una muestra procede de una población con una determinada distribución de probabilidad
  - $H_0$ : Sí procede de  $\xi$
  - $H_1$ : NO procede de  $\xi$
- Procedimiento: Ajuste de una  $\xi$  teórica a la muestra  $X$ 
  - $H_0$ : ajuste bueno
  - $H_1$ : ajuste no bueno

##### 9.7.1. **TEST $\chi^2$**

##### 9.7.1.1. $\xi$ no tiene parámetros

- Procedimiento
  - Se clasifican las muestras en  $r$  clases mutuamente excluyentes y que cubren todo el campo de variación de la distribución  $\xi$ 
    - Clases:  $A_1, A_2, A_3, \dots, A_r$

- Se construye la distribución de frecuencias absolutas de la muestra

| $x_i$ | $n_i$ |
|-------|-------|
| $A_1$ | $n_1$ |
| ...   |       |
| $A_r$ | $n_r$ |

$$\sum_{i=1}^r n_i = n$$

- Se construye la distribución de frecuencias absolutas esperadas  $E_i$  de la población

| $x_i$ | $E_i$ |
|-------|-------|
| $A_1$ | $E_1$ |
| ...   |       |
| $A_r$ | $E_r$ |

$$\sum_{i=1}^r E_i = n$$

- Se establece la medida de discrepancia

$$X^2 = \sum_{i=1}^r \frac{(n_i - E_i)^2}{E_i}$$

- Se considera región crítica

$$X^2 \geq k$$

- Cálculo de  $E_i$

- Si  $H_0$  cierta, se puede calcular  $P(A_i) = p_i$ , resultando  $\sum_{i=1}^r p_i = 1$

- Entonces, la distribución de las frecuencias muestrales es multinomial

$$P(n_1, n_2, \dots, n_r) = \frac{n!}{n_1! n_2! \dots n_r!} p_1^{n_1} p_2^{n_2} \dots p_r^{n_r}$$

por ser cada muestra individual independiente

- Entonces, cada  $n_i$  tiene una distribución binomial  $B(n, p_i)$ , cuyo valor esperado será  $E_i$ :

$$E_i = E(B(n, p_i)) = np_i \quad \text{"Reparto de } n \text{ según probabilidad de clase"}$$

$$\sum_{i=1}^r E_i = \sum_{i=1}^r np_i = n \sum_{i=1}^r p_i = n(1) = n$$

- Distribución de  $X^2$ 
  - Como  $B(n, p_i)$ , converge en Poisson  $Po(np_i)$
  - Por Teorema Central del Límite

$$\xi_i = \frac{n_i - np_i}{\sqrt{np_i}} \rightarrow N(0,1)$$

$$\xi_i^2 = \frac{(n_i - np_i)^2}{np_i}$$

$$\text{Entonces } X^2 = \sum_{i=1}^r \xi_i^2 \rightarrow \chi_r^2$$

$$\text{Pero como } \sum_{i=1}^r n_i = n \rightarrow \chi_r^2$$

- Luego la región crítica es:

$$X^2 \geq k = \chi_{r-1, \alpha}^2$$

- Observaciones:  $E_i \geq 5$
- Ejemplo: Al nivel de significación del 5%, se puede decir que hay diferencia de opinión entre la población si de 5000 personas 2449 contestan SÍ y el resto NO a una pregunta

$H_0$ : ajuste bueno a  $p_i = 1/2$

$H_1$ : ajuste malo a  $p_i = 1/2$

| $A_i$ | $n_i$ | $p_i$         | $E_i = np_i$              | $X^2$                          |               |
|-------|-------|---------------|---------------------------|--------------------------------|---------------|
| SÍ    | 2449  | $\frac{1}{2}$ | $\frac{1}{2} 5000 = 2500$ | $\frac{(2449 - 2500)^2}{2500}$ | 1.0404        |
| NO    | 2551  | $\frac{1}{2}$ | $\frac{1}{2} 5000 = 2500$ | $\frac{(2551 - 2500)^2}{2500}$ | 1.0404        |
|       | 5000  |               | 5000                      |                                | <b>2.0808</b> |

$$k = \chi_{2-1, 0.05}^2 = 3.8415$$

Como  $X^2 \leq k$ , no hay evidencia para rechazar  $H_0$

**9.7.1.2.  $\xi$  tiene k parámetros desconocidos**

- Procedimiento

○ El mismo pero  $X^2 \rightarrow \chi^2_{r-k-1}$

- Ejemplo: Una compañía de seguros registra los accidentes de automóvil de una ciudad durante 100 días, obteniendo la siguiente información:

|               |    |    |    |   |   |   |
|---------------|----|----|----|---|---|---|
| Nº Accidentes | 0  | 1  | 2  | 3 | 4 | 5 |
| Nº días       | 40 | 34 | 16 | 7 | 2 | 1 |

Establecer una hipótesis acerca de la población que representa el evento número de accidentes por día y contrastarla al nivel de significación del 5%.

- $H_0$ : ajuste bueno a Poisson ( $\lambda$ )

$H_1$ : ajuste malo

Como  $\lambda^* = \bar{x} = 1$

- $E_i = np_i$

$$p_i = P(\xi = i) = \frac{\lambda^i e^{-\lambda}}{i!}$$

| $A_i$ | $n_i$ | $p_i$                            | $E_i = np_i$ | $n_i$ | $E_i = np_i$ | $X^2$                          |               |
|-------|-------|----------------------------------|--------------|-------|--------------|--------------------------------|---------------|
| 0     | 40    | $\frac{1^0 e^{-1}}{0!} = 0.3679$ | 36.79        | 40    | 36.79        | $\frac{(40 - 36.79)^2}{36.79}$ | 0.2805        |
| 1     | 34    | $\frac{1^1 e^{-1}}{1!} = 0.3679$ | 36.79        | 34    | 36.79        | $\frac{(34 - 36.79)^2}{36.79}$ | 0.2113        |
| 2     | 16    | 0.1839                           | 18.39        | 16    | 18.39        | $\frac{(16 - 18.39)^2}{18.39}$ | 0.3116        |
| 3     | 7     | 0.0613                           | 6.13         | 10    | 8.02         | $\frac{(10 - 8.03)^2}{8.03}$   | 0.4906        |
| 4     | 2     | 0.0153                           | 1.53         |       |              |                                |               |
| 5     | 1     | 0.0031                           | 0.31         |       |              |                                |               |
| 6     | 0     | 0.0005                           | 0.05         |       |              |                                |               |
|       | 100   | 1                                | 100          | 100   | 100          |                                | <b>1.2904</b> |

$$k = \chi^2_{4-1-1, 0.05} = 5.99$$

Como  $X^2 \leq k$ , no hay evidencia para rechazar  $H_0$

## 9.6. TABLAS DE CONTINGENCIA

- Definición: Una tabla de contingencia  $r \times c$  es una tabla de doble entrada donde se recoge la frecuencia conjunta  $n_{ij}$  con que aparece el nivel  $i$ -ésimo de un factor A con  $r$  niveles y el nivel  $j$ -ésimo de un factor B con  $c$  niveles:

|                | B <sub>1</sub> | ... | B <sub>c</sub> |          |
|----------------|----------------|-----|----------------|----------|
| A <sub>1</sub> | $n_{ij}$       |     | $n_{rc}$       | $n_{1.}$ |
| ...            |                |     |                |          |
| A <sub>r</sub> |                |     |                | $n_{r.}$ |
|                | $n_{.1}$       |     | $n_{.c}$       | $n$      |

### 9.6.1. CONTRASTE DE INDEPENDENCIA

- Hipótesis a contrastar:
  - $H_0$ : Independencia entre niveles de A y B
  - $H_1$ : Dependencia entre niveles de A y B
- Condición de independencia:
 
$$p_{ij} = p_i \cdot p_j = P(A_i \cap B_j) = P(A_i)P(B_j)$$
- Estadístico de contraste:

$$\text{Como } p_{i.MV}^* = \frac{n_{i.}}{n} \text{ y } p_{.j.MV}^* = \frac{n_{.j}}{n}$$

$$E_{ij}^* = np_{ij}^* = n \frac{n_{i.}}{n} \frac{n_{.j}}{n} = \frac{n_{i.} n_{.j}}{n}$$

$$X^2 = \sum_{i=1}^r \sum_{j=1}^c \frac{(n_{ij} - E_{ij})^2}{E_{ij}} \rightarrow \chi_{rc-(r+c-2)-1}^2 = \chi_{(r-1)(c-1)}^2$$

- Región crítica:
 
$$X^2 \geq k = \chi_{(r-1)(c-1), \alpha}^2$$
- Ejemplo: Una empresa dedicada a la venta de automóviles desea determinar si la edad de sus clientes potenciales puede explicar o no la preferencia por tres modelos que va al lanzar al mercado. Consultados 200 clientes habituales, la información obtenida es la siguiente

|      |       | MODELO |       |       |
|------|-------|--------|-------|-------|
|      |       | I      | II    | III   |
| EDAD | 20-30 | 10.00  | 40.00 | 10.00 |
|      | 30-40 | 30.00  | 30.00 | 20.00 |
|      | 40-50 | 10.00  | 30.00 | 20.00 |

¿Aceptaría la empresa a la vista de esta información que la edad media explicará la preferencia por el modelo al nivel de significación del 5%?

Solución:

$H_0$ : Independencia entre niveles de Edad y Modelo

$H_1$ : Dependencia entre niveles de Edad y Modelo

OBSERVADA

|   | 1     | 2      | 3     | 4    | 5    |        |
|---|-------|--------|-------|------|------|--------|
| 1 | 10.00 | 40.00  | 10.00 |      |      | 60.00  |
| 2 | 30.00 | 30.00  | 20.00 |      |      | 80.00  |
| 3 | 10.00 | 30.00  | 20.00 |      |      | 60.00  |
| 4 |       |        |       |      |      | 0.00   |
| 5 |       |        |       |      |      | 0.00   |
|   | 50.00 | 100.00 | 50.00 | 0.00 | 0.00 | 200.00 |

TEÓRICA

|   | 1     | 2      | 3     | 4    | 5    |        |
|---|-------|--------|-------|------|------|--------|
| 1 | 15.00 | 30.00  | 15.00 | 0.00 | 0.00 | 60.00  |
| 2 | 20.00 | 40.00  | 20.00 | 0.00 | 0.00 | 80.00  |
| 3 | 15.00 | 30.00  | 15.00 | 0.00 | 0.00 | 60.00  |
| 4 | 0.00  | 0.00   | 0.00  | 0.00 | 0.00 | 0.00   |
| 5 | 0.00  | 0.00   | 0.00  | 0.00 | 0.00 | 0.00   |
|   | 50.00 | 100.00 | 50.00 | 0.00 | 0.00 | 200.00 |

DIFERENCIA

|   | 1    | 2    | 3    | 4    | 5    |         |
|---|------|------|------|------|------|---------|
| 1 | 1.67 | 3.33 | 1.67 | 0.00 | 0.00 | 6.67    |
| 2 | 5.00 | 2.50 | 0.00 | 0.00 | 0.00 | 7.50    |
| 3 | 1.67 | 0.00 | 1.67 | 0.00 | 0.00 | 3.33    |
| 4 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00    |
| 5 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00    |
|   | 8.33 | 5.83 | 3.33 | 0.00 | 0.00 | 17.5000 |

$$k = \chi^2_{(3-1)(3-1), 0.05} = 9.4877$$

$\therefore$  Como  $X^2 \geq k$ , hay suficiente evidencia para rechazar la hipótesis de independencia

### 9.6.2. CONTRASTE DE HOMOGENEIDAD

- $c$  muestras clasificadas según  $r$  niveles:
- Hipótesis a contrastar:
  - $H_0$ : Las  $c$  muestras SÍ corresponden a la misma población
  - $H_1$ : Las  $c$  muestras NO corresponden a la misma población
- Problema: Para examinar las consecuencias de un conjunto de medidas de política económica se efectúan dos sondeos en dos momentos distintos entre un grupo de 2500 empresas dedicadas a la exportación obteniéndose los siguientes resultados:

|             | SONDEO |     |
|-------------|--------|-----|
|             | I      | II  |
| INCREMENTO  | 60%    | 58% |
| DISMINUCIÓN | 40%    | 42% |

¿Puede afirmarse al nivel de significación del 5% que se han modificado las políticas de exportación?

Solución:

$H_0$ : Las 2 muestras SÍ corresponden a la misma población, o no ha habido cambio de políticas

$H_1$ : Las 2 muestras NO corresponden a la misma población

OBSERVADA

|   | 1       | 2       | 3    | 4    | 5    |         |
|---|---------|---------|------|------|------|---------|
| 1 | 1500.00 | 1450.00 |      |      |      | 2950.00 |
| 2 | 1000.00 | 1050.00 |      |      |      | 2050.00 |
| 3 |         |         |      |      |      | 0.00    |
| 4 |         |         |      |      |      | 0.00    |
| 5 |         |         |      |      |      | 0.00    |
|   | 2500.00 | 2500.00 | 0.00 | 0.00 | 0.00 | 5000.00 |

TEÓRICA

|   | 1       | 2       | 3    | 4    | 5    |         |
|---|---------|---------|------|------|------|---------|
| 1 | 1475.00 | 1475.00 | 0.00 | 0.00 | 0.00 | 2950.00 |
| 2 | 1025.00 | 1025.00 | 0.00 | 0.00 | 0.00 | 2050.00 |
| 3 | 0.00    | 0.00    | 0.00 | 0.00 | 0.00 | 0.00    |
| 4 | 0.00    | 0.00    | 0.00 | 0.00 | 0.00 | 0.00    |
| 5 | 0.00    | 0.00    | 0.00 | 0.00 | 0.00 | 0.00    |
|   | 2500.00 | 2500.00 | 0.00 | 0.00 | 0.00 | 5000.00 |

DIFERENCIA

|   | 1    | 2    | 3    | 4    | 5    |        |
|---|------|------|------|------|------|--------|
| 1 | 0.42 | 0.42 | 0.00 | 0.00 | 0.00 | 0.85   |
| 2 | 0.61 | 0.61 | 0.00 | 0.00 | 0.00 | 1.22   |
| 3 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00   |
| 4 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00   |
| 5 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00   |
|   | 1.03 | 1.03 | 0.00 | 0.00 | 0.00 | 2.0670 |

$$k = \chi^2_{(2-1)(2-1), 0.05} = 3.8415$$

$\therefore$  Como  $X^2 \leq k$ , no hay suficiente evidencia para rechazar la hipótesis de homogeneidad, con lo que no se aprecian cambios significativos de políticas de exportación