

Análisis de la varianza de dos factores

El problema anterior consideraba la comparación de k muestras para detectar diferencias entre las respectivas poblaciones. En el modelo de aleatorización N individuos son asignados al azar a uno de k tratamientos. Sin embargo, las diferencias entre tratamientos podrían verse “oscurecidas” por la variabilidad excesiva entre los individuos dentro de los grupos. Este problema puede resolverse dividiendo a los sujetos en subgrupos homogéneos o bloques y realizando las comparaciones entre los bloques. Se trata de una extensión del problema de muestras apareadas.

El diseño que consideraremos inicialmente es el *diseño en bloques completamente aleatorizado con una observación por celda*.

Se tienen $N=nk$ sujetos divididos en n bloques y los sujetos, dentro de cada bloque, se asignan al azar a uno de los k tratamientos. Otro ejemplo de aplicación de este diseño es el problema de mediciones repetidas, en cuyo caso, el sujeto es el bloque y se realizan k mediciones sobre cada sujeto.

El modelo muestral puede definirse de dos formas:

1) $\vec{X}_i = (X_{i1}, \dots, X_{ik})$ son n v.a. independientes con distribución $F_i(x_1 - \theta_1, \dots, x_k - \theta_k)$ y $F_i(x_1, \dots, x_k) = F_i(x_{p_1}, \dots, x_{p_k})$ para toda permutación (p_1, \dots, p_k) , o sea que X_1, \dots, X_k son canjeables.

2) $X_{ij} \sim F_i(x - \theta_j)$, $F_i \in \Omega_o$ para $i = 1, \dots, k$ y $j = 1, \dots, n$. Es decir que F_i es la distribución de las observaciones del i-ésimo bloque y, dentro del bloque θ_j es la mediana del j-ésimo tratamiento.

Queremos testear

$$H_0: \theta_1 = \theta_2 = \dots = \theta_k \quad \text{vs} \quad H_1: \text{existe al menos un par } (i,j) \text{ tal que } \theta_i \neq \theta_j$$

Test de Friedman (1973): Sea $R_{ij} = R(X_{ij})$ el rango de X_{ij} entre X_{i1}, \dots, X_{ik} . Es decir que R_{ij} es el rango de X_{ij} dentro de su bloque. Entonces

$$R_{.j} = \sum_{i=1}^n R_{ij}$$

es la suma de los rangos correspondientes al tratamiento j. Esquemáticamente, colocando como columnas los tratamientos y los bloques (sujetos) como filas:

	1	2	k
1	R_{11}	R_{12}	R_{1k}
2	R_{21}	R_{22}	R_{2k}
...
n	R_{n1}	R_{n2}	R_{nk}
	$R_{.1}$	$R_{.2}$	$R_{.k}$

Bajo H_0 , y suponiendo que no hay empates, conocemos la distribución de $R_{.1}, \dots, R_{.k}$ pues

$$P(R_{ij} = s) = \frac{1}{k} \quad 1 \leq s \leq k$$

$$P(R_{ij} = s, R_{il} = t) = \frac{1}{k(k-1)} \quad s \neq t \quad j \neq l$$

Entonces,

$$E(R_{ij}) = \frac{k+1}{2} \quad V(R_{ij}) = \frac{k^2-1}{12} \quad \text{cov}(R_{ij}, R_{il}) = -\frac{k+1}{12} \quad \text{si } j \neq l$$

y por lo tanto

$$E(R_{.j}) = \frac{n(k+1)}{2} \quad \text{Var}(R_{.j}) = \frac{n(k^2-1)}{12} \quad \text{cov}(R_{.j}, R_{.l}) = -\frac{n(k+1)}{12} \quad \text{si } j \neq l$$

Friedman propuso el siguiente estadístico:

$$T_1 = \sum_{j=1}^k c_{jN}^2 \left(\frac{R_{.j} - E(R_{.j})}{\sqrt{\text{Var}(R_{.j})}} \right)^2$$

donde los c_{jN} se eligen de manera que el estadístico converja, bajo H_0 a una distribución χ^2_{k-1} .

El estadístico toma la forma

$$T_1 = \sum_{j=1}^k \left(1 - \frac{1}{k} \right) \left(\frac{R_{.j} - n(k+1)/2}{\sqrt{\frac{n(k^2-1)}{12}}} \right)^2 = \left(\frac{12}{nk(k+1)} \sum_{j=1}^k R_{.j}^2 \right) - 3n(k+1)$$

que, bajo H_0 , tiene distribución asintótica χ^2 con $k-1$ grados de libertad. Se rechazará H_0 si

$$T_1 > \chi_{k-1, \alpha}^2$$

En caso en que haya empates, debe hacerse una modificación al estadístico del test de

Friedman. Sean $A_1 = \sum_{i=1}^n \sum_{j=1}^k R_{ij}^2$ $C_1 = \frac{nk(k+1)^2}{4}$

Se define el estadístico modificado:

$$T_1 = \frac{(k-1) \left(\sum_{j=1}^k R_{.j}^2 - nC_1 \right)}{A_1 - C_1} = \frac{(k-1) \sum_{j=1}^k \left(R_{.j} - \frac{n(k+1)}{2} \right)^2}{A_1 - C_1}$$

Si $A_1 = C_1$ se considera que se está en la región crítica y se rechaza H_0 .

Otros estudios (Iman y Davenport, 1980) recomiendan utilizar, no T_1 , sino el estadístico del test clásico de análisis de la varianza calculado sobre los rangos, que se puede expresar como función del estadístico T_1 :

$$T_2 = \frac{(n-1)T_1}{n(k-1) - T_1}$$

Bajo H_0 , T_2 tiene distribución F con $(k-1)$ y $(n-1)(k-1)$ grados de libertad. Se rechaza H_0 si $T_2 > F_{(k-1), (k-1)(n-1), \alpha}$.

Ejemplo: 12 amas de casa son seleccionadas para participar en un experimento de siembra. A cada una de ellas se le pide que seleccione cuatro parcelas idénticas en su jardín y plante 4 tipos distintos de césped, uno en cada parcela. Después de cierto periodo, se les pide que ordenen los 4 tipos de césped por orden de preferencia, asignando el número 1 al césped menos preferido, 2 al siguiente, etc. La hipótesis nula implica que no hay diferencias entre las preferencias de los tipos de césped. Los resultados obtenidos son los siguientes:

Ama de casa	Césped			
	1	2	3	4
1	4	3	2	1
2	4	2	3	1
3	3	1.5	1.5	4
4	3	1	2	4
5	4	2	1	3
6	2	2	2	4
7	1	3	2	4
8	2	4	1	3
9	3.5	1	2	3.5
10	4	1	3	2
11	4	2	3	1
12	3.5	1	2	3.5
$R_{.j}$	38	23.5	24.5	34

Como hay empates, calculamos el valor del estadístico modificado

$$A_1 = 356.5 \quad C_1 = 300 \quad T_1 = 8.097$$

y obtenemos p-valor = $P(\chi_3^2 > 8.097) = 0.044$. Por lo tanto, a nivel 0.05, se rechaza la hipótesis nula.


Calculemos el estadístico T_2 .

$$T_2 = \frac{11(8.097)}{12(3) - 8.097} = 3.19$$


Como la región crítica de nivel 0.05 de la distribución F con 3 y 33 grados de libertad corresponde a valores del estadístico mayores que 2.90, se rechaza la hipótesis nula. El correspondiente p-valor es:

$$\text{p-valor} = P(F_{3,33} > 3.19) = 0.036$$

Procesamiento con S-PLUS: Los datos se ingresaron en un data set denominado "cesped" que contiene 3 variables: tipo (grupos o categorías), ama (bloque) y pref.



Se debe especificar cuál es la variable en estudio, qué variable define el agrupamiento y cuál el bloque.



S-PLUS no utiliza el estadístico T_2 sino T_1 :

Friedman rank sum test

data: pref and tipo and ama from data set cespced
Friedman chi-square = 8.0973, df = 3, p-value = 0.044
alternative hypothesis: two.sided

Comparaciones múltiples: Cuando se rechaza H_0 , es posible realizar tests de comparaciones múltiples en base a R_1, \dots, R_k . En efecto, bajo H_0 ,

$$\frac{R_j - R_i}{\sqrt{\text{Var}(R_j - R_i)}} \xrightarrow{d} N(0,1)$$

siendo $\text{Var}(R_j - R_i) = 2\text{Var}(R_j) - 2\text{cov}(R_j, R_i) = \frac{nk(k+1)}{6}$.

Entonces, diremos que θ_i es significativamente distinto de θ_j a nivel global α si

$$|R_j - R_i| \geq z_{\alpha'/2} \sqrt{\frac{nk(k+1)}{6}} \quad \text{con } \alpha' = \frac{2\alpha}{k(k-1)}$$

Conover sugiere otro método. Diremos que θ_i es significativamente distinto de θ_j a nivel global α si

$$|R_j - R_i| \geq t_{(k-1)(n-1), \alpha/2} \left(\frac{2(nA_1 - \sum R_j^2)}{(k-1)(n-1)} \right)^{1/2}$$

En este caso, el nivel α es el mismo que el utilizado en el test de Friedman. La ecuación anterior puede escribirse en función de T_1 :

$$|R_j - R_i| \geq t_{(k-1)(n-1), \alpha/2} \left[\frac{(A_1 - C_1)2n}{(k-1)(n-1)} \left(1 - \frac{T_1}{n(k-1)} \right) \right]^{1/2}$$

Si no hay empates, $A_1 = nk(k+1)(2k+1)/6$ y $A_1 - C_1 = nk(k+1)(k-1)/12$.

Ejemplo: Dado que en el ejemplo anterior, se rechazó H_0 a nivel 0.05, interesa detectar cuáles son los tipos de césped que difieren en cuanto a la preferencia. Aplicaremos el procedimiento sugerido por Conover. El valor crítico 0.025 de la distribución t con $(11)(3) = 33$ grados de libertad es 2.036, entonces

$$t_{(k-1)(n-1), \alpha/2} \left(\frac{2(nA_1 - \sum R_j^2)}{(k-1)(n-1)} \right)^{1/2} = 11.49$$

El césped tipo 1 resulta ser significativamente diferente de los tipos 2 y 3 y no hay otra diferencia significativa.