

# Test de suma de rangos

**Patricia Kisbye**

FaMAF

8 de junio, 2010

# Bondad de ajuste

- ▶ Se tiene una muestra de datos y se quiere contrastar la hipótesis  $H_0$ ) Los datos provienen de la distribución  $F$ .
  - ▶ Test chi-cuadrado y test de Kolmogorov Smirnov.
- ▶ Se tienen dos muestras de datos:  
 $H_0$ ) los datos de las dos muestras provienen de una misma distribución.
  - ▶ Test de suma de rangos (Mann-Whitney o de Wilcoxon).
- ▶ Se tienen  $k$  muestras,  $k \geq 2$ ,  
 $H_0$ ) Los datos de todas las muestras provienen de una misma distribución.
  - ▶ Test de Kruskal-Wallis.

## El problema de las dos muestras

- ▶ Se han observado  $m$  datos:  $Y_1, \dots, Y_m$ . Por ejemplo, tiempos de permanencia de clientes en un sistema a lo largo de un día.
- ▶ Se establece un modelo matemático para estos datos, asumiendo que las  $Y_i$  son independientes e igualmente distribuidas.
- ▶ Se realiza una simulación de datos  $X_1, \dots, X_n$  de acuerdo a este modelo matemático.
- ▶ ¿Se puede asegurar que  $Y_1, \dots, Y_m, X_1, \dots, X_n$  son independientes e igualmente distribuidas?

$H_0$ ) Las  $n + m$  variables aleatorias  $Y_1, \dots, Y_m, X_1, \dots, X_n$  son independientes e igualmente distribuidas.

# Test de suma de rangos

## **Método:**

Muestra 1:  $X_1, \dots, X_n$

Muestra 2:  $Y_1, \dots, Y_m$

- ▶ **Nota:** Cualquiera de las dos muestras puede elegirse como primera.
- ▶ Se ordenan los  $n + m$  valores, que asumimos todos distintos.
- ▶  $R(x_i)$ : rango de  $x_i$ ,  $i$ -ésimo elemento de la muestra 1, entre los  $n + m$  valores.
- ▶  $R$ : Suma de los rangos de la muestra 1.

$$R = \sum_{i=1}^n R(x_i).$$

- ▶ Ejemplo:

Muestra 1: 0, 17, 13, 16.

Muestra 2: 4, 6, 29.

Ordenamiento: 0, 4, 6, 13, 16, 17, 29.

$$R = 1 + 4 + 5 + 6 = 16$$

# Test de suma de rangos

$R =$  suma de los rangos de la primera muestra. ← Estadístico

- ▶ Un valor grande de  $R$  indica que los datos de la primera muestra son en general mayores que los de la segunda.
- ▶ Un valor chico de  $R$  indica que los datos de la primera muestra son en general menores que los de la segunda.
- ▶ Si el valor observado es  $R = r$ , se rechaza  $H_0$  si son pequeñas alguna de las probabilidades

$$P_{H_0}(R \leq r) \quad \text{o} \quad P_{H_0}(R \geq r).$$

## Ejemplo

- ▶ Se observaron durante 5 días los siguientes valores:

342, 448, 504, 361, 453,

y la simulación del modelo matemático propuesto para el sistema arrojó los siguientes valores:

186, 220, 225, 456, 276, 199, 371, 426, 242, 311.

- ▶ Test de suma de rangos:

186, 199, 220, 225, 242, 276, 311, 342, 361, 371, 426, 448, 453, 456, 504

$$R = 8 + 12 + 15 + 9 + 13 = 57$$

## Cálculo de $P_{H_0}(R \leq r)$

- ▶ Si  $n$  y  $m$  son valores pequeños, puede utilizarse una fórmula recursiva para el cálculo de  $P_{H_0}(R \leq r)$ .
- ▶ Si  $n$  y  $m$  son valores grandes ( $\geq 8$ ), conviene utilizar
  - ▶ distribución de  $R$ , o
  - ▶ simulación.

### **Muestras chicas**

- ▶  $P_{n,m}(r)$ : probabilidad que de dos conjuntos de datos igualmente distribuidos, de tamaños  $n$  y  $m$  respectivamente, la suma de los rangos de los datos del primer conjunto sea menor o igual a  $r$ .
- ▶ Notación:

$$P_{n,m}(r) = P_{H_0}(R \leq r)$$

## Cálculo de $P_{n,m}(r)$

- ▶  $R = r$ : valor observado del rango de la primera muestra (de tamaño  $n$ ).
- ▶ Si el mayor valor es de la primera muestra:

$$r = r - (m + n) + (m + n)$$

- ▶  $r - (m + n)$ : suma de los rangos de los  $n - 1$  restantes.
- ▶  $m + n$ : rango del mayor.

$$P(R \leq r \mid \text{el mayor está en la 1ra. muestra}) = P_{n-1,m}(r - m - n)$$

- ▶ Si el mayor valor corresponde a la segunda muestra, se tiene

$$P(R \leq r \mid \text{el mayor está en la 2da. muestra}) = P_{n,m-1}(r)$$

## Cálculo de $P_{n,m}(r)$

- ▶ Las probabilidades que un elemento de la primera (segunda, respectivamente) muestra sea el mayor son:

$$\frac{n}{m+n} \quad \text{y} \quad \frac{m}{m+n}$$

- ▶ Definición recursiva de  $P_{n,m}(r)$ :

$$P_{n,m}(r) = \frac{n}{n+m} P_{n-1,m}(r-n-m) + \frac{m}{m+n} P_{n,m-1}(r).$$

- ▶ Condiciones iniciales:

$$P_{1,0}(k) = \begin{cases} 0 & k \leq 0 \\ 1 & k > 0. \end{cases} \quad P_{0,1}(k) = \begin{cases} 0 & k < 0 \\ 1 & k \geq 0. \end{cases}$$

# Cálculo recursivo del valor $p$

- ▶ El valor  $p$  está dado por

$$2 \min\{P_{H_0}(R \leq r), P_{H_0}(R \geq r)\}$$

- ▶  $P_{H_0}(R \geq r) = 1 - P_{H_0}(R \leq r - 1)$ .
- ▶ Cálculo del valor  $p$  por recursión:

$$\text{valor } p = 2 \min\{P_{n,m}(r), 1 - P_{n,m}(r - 1)\}.$$

## Desventajas del método recursivo

- ▶ Para  $n = m = 20$ ,  $1 + 2 + \dots + 40 = 820$ , por lo que el rango de la muestra de menor rango podría alcanzar el valor 410.
- ▶ En tal caso, será necesario calcular

$$20 \times 20 \times 410 = 164000$$

valores de  $P_{n,m}(r)$ .

# Distribución del estadístico $R$

- ▶  $H_0$ : Las dos muestras están igualmente distribuidas.
- ▶ Bajo la hipótesis  $H_0$ , todos los ordenamientos de los  $n + m$  valores son igualmente probables.
- ▶ Notación:
  - ▶  $N = n + m$ .
  - ▶  $x_1, \dots, x_n$ : elementos de la primera muestra.
  - ▶  $R(x_i)$ : rango del elemento  $x_i$ ,  $i = 1 \dots n$ .
- ▶  $R = R(x_1) + \dots + R(x_n)$  tiene una distribución aproximadamente normal:

$$\frac{R - E[R]}{\sqrt{\text{Var}(R)}} \sim N(0, 1).$$

## Parámetros de la distribución de $R$ .

$$E[R(x_i)] = \sum_{j=1}^N j \frac{1}{N} = \frac{N+1}{2}.$$

$$E[R] = \sum_{i=1}^n E[R(x_i)] = n \frac{N+1}{2}.$$

$$\text{Var}(R(x_i)) = \frac{(N-1)(N+1)}{12}$$

$$\text{cov}(R(x_i), R(x_j)) = -\frac{N+1}{2}$$

$$\text{Var}(R) = nm \frac{N+1}{12}$$

## Distribución de $R$

- ▶ Bajo la hipótesis  $H_0$  y para  $n$  y  $m$  grandes:

$$W = \frac{R - n \frac{N+1}{2}}{\sqrt{nm \frac{N+1}{12}}} \sim N(0, 1)$$

- ▶ Si  $r \leq E[W]$ , entonces  $P(W \leq r) \leq P(W \geq r)$ .
- ▶ Si  $r \geq E[W]$ , entonces  $P(W \geq r) \leq P(W \leq r)$ .

$$\text{valor } p \approx \begin{cases} 2P(Z < r^*) & \text{si } r \leq n \frac{N+1}{2} \\ 2P(Z > r^*) & \text{caso contrario.} \end{cases}$$

$$r^* = \frac{r - \frac{n(N+1)}{2}}{\sqrt{\frac{nm(N+1)}{12}}}$$

## Ejemplo

- ▶ Los siguientes valores corresponden a observaciones de un sistema durante 5 días:

132, 104, 162, 171, 129

- ▶ La simulación según el modelo matemático propuesto para el sistema arroja los siguientes valores:

107, 94, 136, 99, 114, 122, 108, 130, 106, 88.

- ▶ El rango de la primera muestra resulta

$$12 + 4 + 14 + 15 + 10 = 55.$$

- ▶ ¿Valor  $p$  usando recursión? Ross: 0.0752579. Ejercicio.

## Ejemplo

- ▶ Valor  $p$  por aproximación normal:

$$E[R] = 5 \frac{5 + 10 + 1}{2} = 40, \quad 55 > 40.$$

$$\text{valor } p = 2 P \left( Z \geq \frac{55 - 40}{\sqrt{\frac{50 \times 16}{12}}} \right) = 2 P(Z \geq 1.8371) = 0.066.$$

- ▶ Respuesta exacta: 0.0752579.

# Aproximación mediante simulación

- ▶  $H_0$ : si los  $n + m$  datos son distintos, todos los ordenamientos son igualmente probables.
- ▶ Simulación:
  - ▶ Generar un subconjunto de tamaño  $n$  del conjunto  $1, 2, \dots, n + m$ .
  - ▶ Determinar  $R$ : suma de los elementos generados.
  - ▶ Comparar  $R$  con el valor observado  $r$ .

$$R \geq r \quad R \leq r.$$

- ▶ Repetir los pasos anteriores  $k$  veces.
- ▶ Se habrán obtenido valores  $R_1, \dots, R_k$ .
- ▶ Estimar:

$$P(R \geq r) = \frac{\#\{i \mid R_i \geq r\}}{k}, \quad P(R \leq r) = \frac{\#\{i \mid R_i \leq r\}}{k}.$$

# Caso de datos repetidos

- ▶ Si las muestras tienen datos repetidos, se utiliza como rango el promedio de los rangos de dichos valores.

- ▶ Ejemplo:

Ordenamiento:

- ▶ Muestra 1: 2, 3, 4.

- ▶ Muestra 2: 3, 5, 7.

- ▶ 2, 3, 3, 4, 5, 7

- ▶  $R = 1 + 2.5 + 4 = 7.5$ .

- ▶ En este caso, utilizar la aproximación normal.

# Problema de múltiples muestras

- ▶ Se tienen  $m$  muestras de tamaños  $n_1, n_2, \dots, n_m$ .
- ▶  $R_i$ : rango de la  $i$ -ésima muestra.
- ▶  $n = n_1 + \dots + n_m$ : número total de datos u observaciones.
- ▶  $H_0$ : todas las muestras están igualmente distribuidas  $\Rightarrow$  todos los ordenamientos de los  $n$  datos son igualmente probables.
- ▶  $E[R_i] = n_i \frac{n+1}{2}$ .
- ▶ Estadístico:

$$R = \frac{12}{n(n+1)} \sum_{i=1}^m \frac{(R_i - n_i(n+1)/2)^2}{n_i}.$$

- ▶ Valores chicos de  $R$  no indicarían que haya que rechazar  $H_0$ .

# Problema de múltiples muestras

- ▶ Si se observa  $R = y$ , entonces

$$\text{valor } p = P_{H_0}(R \geq y).$$

- ▶ Si los tamaños de las muestras son grandes,  $R$  puede aproximarse por una distribución chi-cuadrado con  $m - 1$  grados de libertad:

$$\text{valor } p \approx P(\chi_{m-1}^2 \geq y).$$

- ▶ Puede usarse simulación.
- ▶ La aproximación chi-cuadrado también puede utilizarse si hay datos repetidos.