

# Test de Kolmogorov-Smirnov

**Patricia Kisbye**

FaMAF

3 de junio, 2010

# Test de Kolmogorov-Smirnov

## El test chi-cuadrado en el caso continuo

- ▶  $H_0$ : Las v.a.  $Y_1, Y_2, \dots, Y_n$  tienen distribución continua  $F$ .
- ▶ Particionar el rango de  $Y = Y_j$  en  $k$  intervalos distintos:

$$[y_0, y_1), [y_1, y_2), \dots, [y_{k-1}, y_k),$$

- ▶ Considerar las  $n$  v.a. discretizadas  $Y_1^d, Y_2^d, \dots, Y_n^d$  dadas por

$$Y_j^d = i \quad \text{si } Y_j \in [y_{i-1}, y_i).$$

- ▶ La hipótesis nula es entonces  
 $H_0) P(Y_j^d = i) = F(y_i) - F(y_{i-1}), \quad i = 1, \dots, k.$
- ▶ Proceder ahora como en el caso discreto.

# Test de Kolmogorov Smirnov

- ▶ **Inconveniente:** No es sencillo construir los intervalos a partir de las probabilidades.
- ▶ Se pierde información al agrupar los datos en intervalos.
- ▶ **Aconsejable:** Utilizar el test de Kolmogorov-Smirnov.

## Test de Kolmogorov Smirnov

- ▶ Compara las funciones de distribución empírica de la muestra y la que se desea contrastar.
- ▶ Es aplicable a distribuciones continuas.
- ▶ Para distribuciones discretas, los valores críticos no están tabulados.
- ▶ Para distribuciones continuas, los valores críticos están tabulados para:
  - ▶ distribuciones con parámetros especificados,
  - ▶ algunas distribuciones con parámetros no especificados (normal, Weibull, gamma, exponencial).

# Aplicación del test K-S

- ▶ Observar  $Y_1, Y_2, \dots, Y_n$  y considerar la distribución empírica

$$F_e(x) = \frac{\#\{j \mid Y_j \leq x\}}{n}.$$

- ▶  $F_e(x)$ : proporción de valores observados menores o iguales a  $x$ .
- ▶ Hipótesis nula:  $F_e(x)$  es “cercana” a  $F(x)$ .
- ▶ **Estadístico de Kolmogorov-Smirnov**

$$D \equiv \max_x |F_e(x) - F(x)|, \quad -\infty < x < \infty.$$

# Implementación

- ▶ Ordenar los datos observados  $Y_1 = y_1, Y_2 = y_2, \dots, Y_n = y_n$  en orden creciente:

$y_{(j)}$  =  $j$  -ésimo valor más pequeño


$$y_{(1)} < y_{(2)} < \dots < y_{(n)}.$$

- ▶ Por ejemplo:  $y_1 = 3, y_2 = 5, y_3 = 1$  y  $n = 3$ , entonces

$$y_{(1)} = 1, y_{(2)} = 3, y_{(3)} = 5.$$

Distribución empírica  $\Rightarrow F_e(x) = \begin{cases} 0 & x < y_{(1)} \\ \frac{1}{n} & y_{(1)} \leq x < y_{(2)} \\ \vdots & \\ \frac{j}{n} & y_{(j)} \leq x < y_{(j+1)} \\ \vdots & \\ 1 & y_{(n)} \leq x \end{cases}$

# Gráficamente



# Estadístico de Kolmogorov-Smirnov

$$D \equiv \sup_{-\infty < x < \infty} |F_e(x) - F(x)|$$


- ▶ Podemos considerar las diferencias  $F_e(x) - F(x)$  y  $F(x) - F_e(x)$  y analizar sus valores máximos (supremos).

$$D^+ = \sup_{-\infty < x < \infty} \{F_e(x) - F(x)\}, \quad D^- = \sup_{-\infty < x < \infty} \{F(x) - F_e(x)\}.$$

- ▶  $F_e(y_{(n)}) = 1$ . Por lo tanto,  $D^+ \geq 0$ .
- ▶  $F_e(x) = 0$  si  $x < y_{(1)}$ , por lo que  $D^- \geq 0$ .

$$D = \max\{D^+, D^-\}$$

# El estadístico $D$



# Cálculo de $D$

Notemos que:

- ▶  $D^+$  se alcanza en el límite inferior de algún intervalo, ya que  $F(x)$  es creciente y  $F_e(x)$  es constante en  $[y_{(j-1)}, y_{(j)}]$ :

$$D^+ = \max_{1 \leq j \leq n} \{ F_e(y_{(j)}) - F(y_{(j)}) \} = \max_{1 \leq j \leq n} \left\{ \left( \frac{j}{n} \right) - F(y_{(j)}) \right\}$$

- ▶  $D^-$  es el límite **por izquierda** calculado en el extremo derecho de algún intervalo, ya que  $F_e(x)$  es discontinua en tal punto:

$$F_e(y_{(j)}) = \frac{j}{n} = F_e(y_{(j)} - \epsilon) + \frac{1}{n}, \quad \epsilon \text{ pequeño.}$$

$$D^- = \max_{1 \leq j \leq n} \{ F(y_{(j)}) - F_e(y_{(j-1)}) \} = \max_{1 \leq j \leq n} \left\{ F(y_{(j)}) - \frac{j-1}{n} \right\}$$

# Estadístico de Kolmogorov-Smirnov

$$D = \max_{1 \leq j \leq n} \left\{ \frac{j}{n} - F(y_{(j)}), F(y_{(j)}) - \frac{j-1}{n} \right\} \leftarrow \text{Estadístico de K-S}$$

- ▶ Elegir un grado de significación (nivel de rechazo)  $\alpha$ .
- ▶ Tomar la muestra y ordenar los datos observados.
- ▶ Calcular el estadístico  $D$  en los datos observados.
- ▶ Valor observado:  $D = d$ .
- ▶ Calcular el valor  $p = P_F(D \geq d)$ .
  - ▶ valor  $p < \alpha$ : se rechaza  $H_0$ .
  - ▶ valor  $p > \alpha$ : no se rechaza  $H_0$ .
- ▶ ¿Cómo calcular el valor  $p$ ?
- ▶ ¿Cuál es la distribución del estadístico  $D$ ?

# Estimación del valor $p$

$P_F(D \geq d)$  no depende de la distribución  $F$ .

- ▶ El estadístico  $D$  depende de las  $n$  observaciones  $Y_1, Y_2, \dots, Y_n$ :

$$D = \sup_x |F_e(x) - F(x)| = \sup_x \left| \frac{\#\{i \mid Y_i \leq x\}}{n} - F(x) \right|$$

- ▶ Si  $Y$  tiene distribución  $F$  entonces

$$F(Y) \sim \mathcal{U}(0, 1).$$

- ▶ Como  $F$  es una función creciente, entonces

$$Y_i \leq x \quad \text{implica} \quad F(Y_i) \leq F(x).$$

## Estimación del valor $p$

$$D = \sup_x \left| \frac{\#\{i \mid F(Y_i) \leq F(x)\}}{n} - F(x) \right|$$

Equivalentemente, se puede reemplazar

- ▶  $F(Y_i)$  por  $U_i$ , v.a. uniformemente distribuida en  $(0, 1)$ , y
- ▶  $F(x)$  por  $y \in [0, 1]$ .

$$D = \sup_{0 \leq y \leq 1} \left| \frac{\#\{i \mid U_i \leq y\}}{n} - y \right|$$

# Estimación del valor $p$

$$D = \sup_{0 \leq y \leq 1} \left| \frac{\#\{i \mid U_i \leq y\}}{n} - y \right|$$

- ▶ Esta expresión no depende de la distribución  $F$ .

$$\text{valor } p = P_F(D \geq d) = P_U(D \geq d), \quad U \sim \mathcal{U}(0, 1).$$

- ▶ Puede estimarse mediante simulación:
  - ▶ Generar  $n$  números aleatorios  $U_i$ ,  $1 \leq i \leq n$ ,
  - ▶ Evaluar  $D$  y comparar con el valor observado  $d$  de la muestra original.


$$\sup_{0 \leq y \leq 1} \left| \frac{\#\{i \mid U_i \leq y\}}{n} - y \right| \geq d$$

- ▶ Repetir el procedimiento  $r$  veces.
- ▶ Se estima el valor  $p$  como la proporción de veces que se cumple la desigualdad  $D \geq d$ .

# Estimación del valor $p$

$$\sup_{0 \leq y \leq 1} \left| \frac{\#\{j \mid U_j \leq y\}}{n} - y \right| \geq d$$

- ▶ Para calcular este supremo, procedemos como para el cálculo de  $d$ .



- ▶ Ordenar  $u_{(1)}, \dots, u_{(n)}$ .
- ▶ Calcular

$$\max_{1 \leq j \leq n} \left\{ \frac{j}{n} - u_{(j)}, u_{(j)} - \frac{j-1}{n} \right\}$$


## Ejemplo

- Si  $n = 3$  y  $U_1 = 0.7$ ,  $U_2 = 0.6$ ,  $U_3 = 0.4$ , entonces

$$U_{(1)} = 0.4, \quad U_{(2)} = 0.6, \quad U_{(3)} = 0.7,$$

y el valor  $D$  para este conjunto de datos es

$$D = \max \left\{ \frac{1}{3} - 0.4, \frac{2}{3} - 0.6, 1 - 0.7, 0.4, 0.6 - \frac{1}{3}, 0.7 - \frac{2}{3} \right\} = 0.4$$



## Ejemplo

- ▶ Se quiere probar la hipótesis que una determinada distribución es exponencial con media 100

$$F(x) = 1 - e^{-x/100}.$$

Los valores ordenados para una muestra de tamaño 10 para esta distribución son:

66, 72, 81, 94, 112, 116, 124, 140, 145, 155,

¿qué conclusión puede obtenerse?

## Ejemplo

$j$	valores	$F(j/n)$	$\frac{j}{n} - F\left(\frac{j}{n}\right)$	$\frac{j-1}{n} - F\left(\frac{j}{n}\right)$
1	66	0,48	-0,38	0,48
2	72	0,51	-0,31	0,41
3	81	0,56	-0,26	0,36
4	94	0,61	-0,21	0,31
5	112	0,67	-0,17	0,27
6	116	0,69	-0,09	0,19
7	124	0,71	-0,01	0,11
8	140	0,75	0,05	0,05
9	145	0,77	0,13	-0,03
10	155	0,79	0,21	-0,11
				$d = 0,48315$

- ▶ Calcular el valor  $p$  mediante simulaciones.
- ▶ Si el  $p$  valor es 0.012, se rechaza la hipótesis nula.

# Pruebas de bondad de ajuste si hay parámetros no especificados

## Caso discreto: test chi-cuadrado

Dadas  $n$  observaciones,  $Y_1, \dots, Y_n$ , éstas se agrupan en  $k$  intervalos distintos. La hipótesis nula está dada por

$$H_0) P(Y_i = j) = p_j, \text{ para } 1 \leq j \leq k, i = 1 \dots n..$$

- ▶ En algunos casos se tiene alguna hipótesis sobre la forma de la distribución pero no sobre los parámetros de la misma: media, desviación estándar, varianza, etc.
- ▶ Esto puede implicar que se desconozca  $p_j$ :

$$P(Y = j) = \frac{e^{-\lambda} \lambda^j}{j!} \Rightarrow \text{¿}\lambda \text{ desconocido?}$$

- ▶ En este caso, se estiman el o los parámetros desconocidos a partir de la muestra.

## El caso discreto

- ▶ A partir de estas estimaciones, se obtienen las probabilidades estimadas:  $\hat{p}_j$ .
- ▶ El estadístico es el siguiente:

$$T = \sum_{j=1}^k \frac{(N_j - n\hat{p}_j)^2}{n\hat{p}_j}$$

- ▶  $N_j$ : cantidad de observaciones en el  $j$ -ésimo intervalo.
  - ▶  $\hat{p}_j$ : probabilidad estimada, según  $H_0$ , que  $Y_j$  caiga en la región  $j$ .
- ▶ Si el valor observado del estadístico es  $t$ , y se han debido estimar  $m$  parámetros:

$$\text{valor } p = P(T \geq t) \approx P(\chi_{k-1-m}^2 \geq t).$$

## Ejemplo

En un período de 30 días se registraron 6 días sin accidentes, 2 con un accidente, 1 con dos accidentes, 9 con 3 accidentes, 7 con 4 accidentes, 4 con 5 accidentes y 1 con 8 accidentes. Realizar una prueba de hipótesis para determinar si el número de accidentes sigue una distribución de Poisson.

- ▶ Estimamos la media  $\lambda$  de la distribución:  
número de accidentes =

$$6 \cdot 0 + 2 \cdot 1 + 1 \cdot 2 + 9 \cdot 3 + 7 \cdot 4 + 4 \cdot 5 + 1 \cdot 8 = 87.$$

$$\hat{\lambda} = \frac{\text{número de accidentes}}{\text{total de días}} = \frac{87}{30} = 2.9$$

$$\hat{p}_{j+1} = P(Y = j) = e^{-2.9} \frac{(2.9)^j}{j!}, \quad j = 0, 1, 2, \dots$$

## Ejemplo

- ▶ Se establecen los  $k$  intervalos. Elegimos  $k = 6$ :

$$l_1 = \{0\}$$
$$l_2 = \{1\}$$

$$l_3 = \{2\}$$
$$l_4 = \{3\}$$

$$l_5 = \{4\}$$
$$l_6 = \{5, 6, 7, \dots\}$$

$$\hat{p}_1 = 0.0500$$
$$\hat{p}_4 = 0.2237$$

$$\hat{p}_2 = 0.1596$$
$$\hat{p}_5 = 0.1622$$

$$\hat{p}_3 = 0.2312$$
$$\hat{p}_6 = 0.1682$$

- ▶ Frecuencias observadas:  $N_1 = 6, N_2 = 2, N_3 = 1, N_4 = 9, N_5 = 7, N_6 = 5$ .
- ▶ Frecuencias esperadas:  $30 \hat{p}_j, 1 \leq j \leq 6$ .
- ▶ Estadístico:

$$T = \sum_{j=1}^6 \frac{(N_j - 30 \hat{p}_j)^2}{30 \hat{p}_j} = 19.887.$$

## Valor $p$

- ▶ El valor observado del estadístico es  $t = 19.887$ .
- ▶ Como se estimó **1 parámetro**, y se consideraron **6 intervalos**, se estima el valor  $p$  utilizando una distribución  $\chi^2$  con  $6 - 1 - 1 = 4$  grados de libertad:

$$\text{valor } p \approx P(\chi_4^2 > 19.887) = 0.0005.$$

- ▶ Conclusión: se rechaza la hipótesis nula.

### Simulación para determinar el valor $p$

- ▶ La hipótesis nula no especifica completamente la distribución.
- ▶ El procedimiento es similar al caso anterior, pero los parámetros deben estimarse nuevamente en cada simulación.

# Valor $p$ con parámetros estimados

## - El modelo

- ▶  $H_0$ ) Los datos de la muestra  $Y_1, Y_2, \dots, Y_n$  provienen de una distribución determinada, salvo por un conjunto de parámetros desconocidos  $\theta_1, \dots, \theta_m$ .

## Primer paso

- ▶  $\hat{\theta}_j$ : estimación de  $\theta_j$  a partir de la muestra,  $j = 1, 2, \dots, m$ .
- ▶  $\hat{p}_j$ : si la distribución tiene parámetros  $\hat{\theta}_1, \dots, \hat{\theta}_m$ .
- ▶ Estadístico  $T$ :

$$T = \sum_{j=1}^k \frac{(N_j - n\hat{p}_j)^2}{n\hat{p}_j}$$

- ▶  $t \leftarrow$  valor observado del estadístico  $T$ .

# Valor $p$ con parámetros estimados

## Simulación

- ▶ Objetivo: estimar el valor  $p$ .
- ▶  $\hat{F}$ : distribución propuesta en  $H_0$ , con los parámetros estimados según la muestra.

El procedimiento consiste en repetir  $r$  veces los siguientes pasos:

1. Generar  $Y_1, \dots, Y_n \sim \hat{F}$ .
2. Calcular  $N_j = \#\{i \mid Y_i \in I_j\}$ ,  $j = 1, \dots, k$ .
3.  $\hat{\theta}_{1,sim}, \dots, \hat{\theta}_{m,sim}$ : estimaciones de los parámetros a partir de los valores  $Y_j$  generados.
4.  $\tilde{p}_j(sim)$ , probabilidades si la distribución tiene parámetros  $\hat{\theta}_{1,sim}, \dots, \hat{\theta}_{m,sim}$ .
5. Calcular  $T^*$ :

$$T^* = \sum_{j=1}^k \frac{(N_j - n\tilde{p}_j)^2}{n\tilde{p}_j}$$

# Valor $p$ con parámetros estimados

Luego de  $r$  pasos se han obtenido  $r$  valores para  $T^*$ :

$$T_1^*, T_2^*, \dots, T_r^*.$$

$$\text{valor } p \approx \frac{\#\{j \mid T_j^* \geq t\}}{r}$$

## Ejemplo

- ▶ Parámetro estimado:  $\hat{\lambda} = 2.9$ .
- ▶ Valor del estadístico según la muestra:  $t = 19.887$
- ▶ Simulación:
  1. Generar 30 v.a. Poisson con media 2.9.
  2.  $\hat{\lambda}_{sim}$ : estimación de  $\lambda$  según esta muestra.
  3.  $p_i^*$ : Probabilidad de tomar el valor  $i$  según una Poisson de parámetro  $\hat{\lambda}_{sim}$ .
  4. Calcular  $T^*$ .
  5. valor  $p$ : proporción de valores de  $T^*$  mayores a 19.887.

# Test de Kolmogorov-Smirnov si hay parámetros no especificados

## Caso continuo

$H_0$ ): Las v. a.  $Y_1, \dots, Y_n$  provienen de una distribución  $F$  con parámetros desconocidos  $\theta_1, \dots, \theta_m$ .

- ▶ Tomar una muestra  $Y_1, \dots, Y_n$ .
- ▶ Estimar los parámetros a partir de la muestra:  $\hat{\Theta} = (\hat{\theta}_1, \dots, \hat{\theta}_m)$ .
- ▶ Calcular el estadístico a partir de la distribución con parámetros estimados:

$$D = \sup_x |F_e(x) - F_{\hat{\Theta}}(x)|.$$

- ▶  $d \leftarrow$  valor de  $D$  observado.

$$\text{valor } p \approx P_{F_{\hat{\Theta}}}(D \geq d) = P_U(D \geq d).$$

- ▶ Este valor **sobreestima** el valor de  $p$ .

# Simulación del valor $p$

- ▶ Si  $p < \alpha$ , se rechaza la hipótesis nula.
- ▶ Si está próximo o es mayor que  $\alpha$ , se optimiza la estimación del valor  $p$ .
- ▶ Optimización: Luego de calcular  $d$ , a partir de la muestra:
  1. Generar  $Y_1, \dots, Y_n$  según la distribución  $F_{\hat{\Theta}}$ .
  2.  $\hat{\Theta}_{sim} = (\hat{\theta}_{1,sim}, \dots, \hat{\theta}_{m,sim})$ : estimación de los parámetros según los datos simulados.
  3.  $F_{e,sim}$ : distribución empírica de los datos simulados.
  4. Calcular el estadístico  $D^*$ :

$$D^* = \sup_x \left| F_{e,sim}(x) - F_{\hat{\Theta}_{sim}}(x) \right|$$

- ▶ Repetir el procedimiento  $r$  veces, para obtener  $D_1^*, \dots, D_r^*$ :

$$\text{valor } p \approx \frac{\#\{j \mid D_j^* \geq d\}}{r}$$