

# Solución del Examen

Dr. Olivier Nuñez Boyer

Junio del 2001

## Problema 1.

1. Denotamos  $p_j^0 = P(X = j)$ ,  $j = 0, 1, \dots, 7$ , donde  $X$  sigue una binomial  $B(7; \frac{1}{2})$  y  $N_j$  es el número de días en los cuales se observó ( $X = j$ ). Para contrastar  $H_0$ , se utiliza el estadístico de Pearson :

$$K_n = n \sum_{j=0}^7 \frac{\left(\frac{N_j}{n} - p_j^0\right)^2}{p_j^0},$$

donde  $n = 250$ . Utilizando la tabla de la binomial se obtiene  $K_{250} \simeq 79.31$  que comparamos con el cuantil  $\chi_{8-1,5\%}^2 = 14.07$  puesto que aquí tenemos 8 categorías. Tenemos que  $K_{250} > \chi_{8-1,5\%}^2$  por tanto rechazamos  $H_0$  con un nivel asintótico  $\alpha = 5\%$ .

- (a) Si  $X_i$  es el número de retrasos observado el  $i^{esimo}$  día, tenemos que la verosimilitud del conjunto de observaciones diarias será

$$\begin{aligned} L(\theta) &= \prod_{i=1}^n \binom{7}{X_i} \theta^{X_i} (1 - \theta)^{7 - X_i} \\ &= C \theta^{\sum_{i=1}^n X_i} (1 - \theta)^{7n - \sum_{i=1}^n X_i}, \end{aligned}$$

donde  $C$  es una constante que no depende de  $\theta$ . Por tanto la log-verosimilitud será

$$\begin{aligned} l(\theta) &= \ln(L(\theta)) \\ &= \ln C + \ln(\theta) \sum_{i=1}^n X_i + \ln(1 - \theta) \left(7n - \sum_{i=1}^n X_i\right). \end{aligned}$$

Se obtiene que la ecuación  $l'(\hat{\theta}) = 0$  es equivalente a

$$(1 - \hat{\theta}) \sum_{i=1}^n X_i = \hat{\theta} \left( 7n - \sum_{i=1}^n X_i \right),$$

o sea  $\hat{\theta} = \frac{1}{7n} \sum_{i=1}^n X_i$ .

- (b) Obtenemos  $\hat{\theta} = \frac{1}{7 \times 250} (0 \times 7 + \dots + 7 \times 2) \simeq 0.4$ . Si denotamos  $\hat{p}_j = P(X = j)$  donde  $X$  sigue una binomial  $B(7; \hat{\theta})$ , el estadístico del  $\chi^2$  para contrastar la hipótesis  $H_0$  múltiple será:

$$K_n^* = n \sum_{j=0}^7 \frac{\left( \frac{N_j}{n} - \hat{p}_j \right)^2}{\hat{p}_j} \simeq 6.21.$$

Puesto que el cuantil  $\chi_{8-1-1,5\%}^2 = 12.59$  es superior a  $K_n^*$  aceptamos  $H_0$  con un nivel asintótico  $\alpha = 5\%$ .

## Problema II.

1. El estimador máximo verosímil de  $\sigma^2$  basado en una muestra de  $N$  observaciones  $(Z_1, \dots, Z_N)$  de una normal  $N(\mu, \sigma^2)$  donde  $\mu$  es conocido es

$$\hat{\sigma}^2 = \frac{1}{N} \sum_{i=1}^N (Z_i - \mu)^2.$$

Por tanto bajo cualquier hipótesis, tenemos que  $\hat{\sigma}_A^2 = \frac{1}{n} \sum_{i=1}^n (X_i - 1)^2$ ,  $\hat{\sigma}_B^2 = \frac{1}{m} \sum_{j=1}^m (Y_j - 1)^2$

y bajo  $H_0 : \sigma_A^2 = \sigma_B^2 = \sigma_0^2$ , tenemos que  $\hat{\sigma}_0^2 = \frac{1}{n+m} \left( \sum_{i=1}^n (X_i - 1)^2 + \sum_{j=1}^m (Y_j - 1)^2 \right)$ .

2. La razón de verosimilitud se escribe

$$\begin{aligned} \Lambda(x, y) &= \frac{\max_{H_0 \cup H_1} L(\sigma_A^2, \sigma_B^2)}{\max_{H_0} L(\sigma_A^2, \sigma_B^2)}, \\ &= \frac{L(\hat{\sigma}_A^2, \hat{\sigma}_B^2)}{L(\hat{\sigma}_0^2, \hat{\sigma}_0^2)} \end{aligned}$$

donde

$$L(\sigma_A^2, \sigma_B^2) = \frac{1}{(2\pi\sigma_A^2)^{\frac{n}{2}}} \exp\left(-\frac{1}{2\sigma_A^2} \sum_{i=1}^n (X_i - 1)^2\right) \frac{1}{(2\pi\sigma_B^2)^{\frac{m}{2}}} \exp\left(-\frac{1}{2\sigma_B^2} \sum_{i=1}^m (Y_j - 1)^2\right)$$

es la verosimilitud de las observaciones. Se obtiene que

$$\Lambda(x, y) = \frac{(\hat{\sigma}_0^2)^{\frac{n+m}{2}}}{(\hat{\sigma}_A^2)^{\frac{n}{2}} (\hat{\sigma}_B^2)^{\frac{m}{2}}}.$$

Por tanto  $2 \ln \Lambda(x, y) = (n + m) \ln (\hat{\sigma}_0^2) - n \ln (\hat{\sigma}_A^2) - m \ln (\hat{\sigma}_B^2)$ . Como bajo  $H_1$  la dimensión del vector de parámetros  $(\sigma_A^2, \sigma_B^2)$  es 2 y bajo  $H_0$  es 1, tenemos que aproximadamente  $2 \ln \Lambda(x, y)$  sigue un  $\chi^2$  con 1 grado de libertad. El test con nivel asintótico  $\alpha = 5\%$  será :

$$\phi = \begin{cases} 1 & \text{si } (n + m) \ln (\hat{\sigma}_0^2) - n \ln (\hat{\sigma}_A^2) - m \ln (\hat{\sigma}_B^2) > \chi_{1,5\%}^2 \\ 0 & \text{en caso contrario} \end{cases}$$

3. Se obtiene que  $2 \ln \Lambda(x, y) \simeq 2.05$  y  $\chi_{1,5\%}^2 = 3.841$  por tanto se acepta  $H_0$ .

### Problema III.

1. Tenemos que  $w(1, \theta) = \begin{cases} 0 & \text{si } \theta < 0 \\ \theta & \text{si } \theta \geq 0 \end{cases}$  y  $w(0, \theta) = \begin{cases} -\theta & \text{si } \theta < 0 \\ 0 & \text{si } \theta \geq 0 \end{cases}$  por tanto  $w(d, \theta)$  es siempre no negativa.
- 2.

$$\begin{aligned} \bar{w}_Q(d) &= E[w(d, \theta)] \\ &= dE(\theta) - E[\theta I_{\{\theta < 0\}}] \\ &= d \times 0 - \frac{1}{2} \int_{-1}^1 \theta I_{\{\theta < 0\}} d\theta \\ &= \frac{1}{2} \int_{-1}^0 \theta d\theta = \frac{1}{2} \left[ \frac{\theta^2}{2} \right]_{-1}^0 = \frac{1}{4}. \end{aligned}$$

Puesto que este riesgo no depende de  $d$ , cualquier decisión vale.

- (a) Conociendo  $\theta$ , la probabilidad de que el accionista venda su acción es  $P(X = 1 | \theta) = \frac{1}{2+\theta}$ . Por tanto, si  $\theta > 0$  (el valor de la acción aumentara el día siguiente) la probabilidad de vender su acción será mas pequeña que si  $\theta < 0$ . La decisión de este accionista siendo sensata, esto justifica la decisión  $d(X)$  que reproduce la de este accionista.

(b) Tenemos que

$$\begin{aligned}\frac{1}{2} \int_{-1}^1 \frac{\theta}{2+\theta} d\theta &= \frac{1}{2} \int_{-1}^1 \frac{2+\theta-2}{2+\theta} d\theta \\ &= \frac{1}{2} \int_{-1}^1 \left[ 1 - \frac{2}{2+\theta} \right] d\theta \\ &= \frac{1}{2} \int_{-1}^1 d\theta - \int_{-1}^1 \frac{1}{2+\theta} d\theta \\ &= 1 - [\ln(2+\theta)]_{-1}^1 = 1 - \ln(3)\end{aligned}$$

(c) Por definición del riesgo bayesiano de una decisión basado en una información muestral, tenemos que

$$\begin{aligned}W_Q(d(X)) &= E[w(d(X), \theta)] \\ &= E[d(X)\theta] - E[\theta I_{\{\theta < 0\}}] \\ &= E[E(d(X)\theta | \theta)] + \frac{1}{4} \\ &= E[P(d(X) = 1 | \theta) \theta] + \frac{1}{4} \\ &= E[P(X = 1 | \theta) \theta] + \frac{1}{4} \\ &= E\left[\frac{\theta}{2+\theta}\right] + \frac{1}{4} = 1 - \ln(3) + \frac{1}{4} < \frac{1}{4}\end{aligned}$$

Deducimos que  $W_Q(d(X)) < \bar{w}_Q(d)$ . Por tanto, la decisión basada en la información muestral es mejor que cualquier decisión que se basa solamente en la distribución *a priori* de  $\theta$ .