

1. Para  $x_1, \dots, x_k$ , muestra aleatoria desde una distribución  $\text{Bin}(n, p)$ . Tenemos,

$$\mu_1 = np, \quad \mu_2 = npq + (np)^2,$$

con  $q = 1 - p$ . Substituyendo  $\mu_1$  en  $\mu_2$ , tenemos

$$\mu_2 = \mu_1 q + \mu_1^2 = \mu_1(1 - p) + \mu_1^2 = \mu_1 - \mu_1 p + \mu_1^2,$$

es decir,  $\mu_1 p = \mu_1 - (\mu_2 - \mu_1^2)$ , lo que lleva a

$$p = 1 - \frac{\mu_2 - \mu_1^2}{\mu_1}.$$

Mientras que

$$n = \frac{\mu_1}{p} = \frac{\mu_1}{1 - (\mu_2 - \mu_1^2)/\mu_1} = \frac{\mu_1^2}{\mu_1 - (\mu_2 - \mu_1^2)}.$$

Finalmente, substituyendo por sus contrapartes muestrales, obtenemos

$$\hat{p}_{\text{MM}} = 1 - \frac{m_2 - \bar{x}^2}{\bar{x}} = 1 - \frac{s^2}{\bar{x}},$$

$$\hat{n}_{\text{MM}} = \frac{\bar{x}^2}{\bar{x} - s^2}.$$

2. Se desea obtener  $\tilde{\theta}_1, \tilde{\theta}_2$  tal que maximicen la función de log-verosimilitud

$$\begin{aligned} \ell(\boldsymbol{\theta}) &= \ell(\theta_1, \theta_2, \theta_1 + \theta_2) \\ &= \log(\theta_1) \sum_{i=1}^n X_i + \log(\theta_2) \sum_{i=1}^n Y_i + \log(\theta_1 + \theta_2) \sum_{i=1}^n Z_i \\ &\quad - n\theta_1 - n\theta_2 - n(\theta_1 + \theta_2) - \sum_{i=1}^n \log(X_i! Y_i! Z_i!), \end{aligned}$$

dividiendo por  $n$  y desconsiderando aquellos términos que no dependen de  $\boldsymbol{\theta}$ , sigue

$$\bar{X} \log \theta_1 + \bar{Y} \log \theta_2 + \bar{Z} \log(\theta_1 + \theta_2) - 2(\theta_1 + \theta_2).$$

Derivando con relación a  $\theta_1$  y  $\theta_2$  e igualando a cero, resulta

$$\frac{\bar{X}}{\theta_1} + \frac{\bar{Z}}{\theta_1 + \theta_2} = 2, \tag{1}$$

$$\frac{\bar{Y}}{\theta_2} + \frac{\bar{Z}}{\theta_1 + \theta_2} = 2. \tag{2}$$

De este modo,  $\bar{X}/\theta_1 = \bar{Y}/\theta_2$  y por tanto

$$\frac{\bar{Z}}{\tilde{\theta}_1 + \tilde{\theta}_2} = \frac{\bar{Z}}{\tilde{\theta}_2(1 + \bar{X}/\bar{Y})}.$$

Usando en (2), obtenemos

$$2\tilde{\theta}_2 = \bar{Y} + \frac{\bar{Z}}{1 + \bar{X}/\bar{Y}} = \bar{Y} \left( \frac{\bar{X} + \bar{Y} + \bar{Z}}{\bar{X} + \bar{Y}} \right).$$

Lo que lleva a

$$\tilde{\theta}_1 = \frac{\bar{X}}{2} \left( \frac{\bar{X} + \bar{Y} + \bar{Z}}{\bar{X} + \bar{Y}} \right), \quad \tilde{\theta}_2 = \frac{\bar{Y}}{2} \left( \frac{\bar{X} + \bar{Y} + \bar{Z}}{\bar{X} + \bar{Y}} \right),$$

y

$$\tilde{\theta}_3 = \tilde{\theta}_1 + \tilde{\theta}_2 = \frac{\bar{X} + \bar{Y} + \bar{Z}}{2}.$$

3. Para  $X \sim U(0, \theta)$ , tenemos que  $E(X) = \theta/2$ . De este modo,

$$\hat{\theta}_{MM} = 2\bar{X}.$$

Por otro lado, para una muestra aleatoria  $x_1, \dots, x_n$  desde una distribución  $U(0, \theta)$ , la función de verosimilitud es dada por

$$L(\theta; \mathbf{x}) = \frac{1}{\theta^n} \prod_{i=1}^n I_{[0, \theta]}(x_i).$$

Ahora, notando que  $0 \leq x_i \leq \theta$  puede ser escrito como  $x_i \leq \theta < \infty$ , sigue que

$$\prod_{i=1}^n I_{[x_i, \infty)}(\theta) = 1 \iff I_{[x_i, \infty)}(\theta) = 1, \forall i,$$

es decir,  $x_i \leq \theta$  para todo  $i$ . Sea  $x_{(n)} = \max\{x_1, \dots, x_n\}$ . Por tanto,

$$x_i \leq \theta, \forall i, \iff x_{(n)} \leq \theta, \iff I_{[x_{(n)}, \infty)}(\theta) = 1,$$

así, podemos escribir

$$L(\theta; \mathbf{x}) = \frac{1}{\theta^n} I_{[x_{(n)}, \infty)}(\theta).$$

Debido a que  $1/\theta^n$  es función monótona decreciente, sigue que

$$L(\theta; \mathbf{x}) \leq \frac{1}{x_{(n)}^n},$$

y por tanto  $\hat{\theta}_{ML} = X_{(n)}$ . Por otro lado, note que las función de distribución y de densidad del máximo para  $Z_1, \dots, Z_n$  variables IID cada una con CDF  $F$  y densidad  $f$  son dadas, respectivamente, por:

$$F_{\max}(t) = P(Z_i \leq t, \forall i) = F^n(t), \quad \text{y} \quad f_{\max}(t) = n f(t) F^{n-1}(t).$$

De este modo, para  $X_1, \dots, X_n$  variables IID desde  $U(0, \theta)$ , obtenemos:

$$E(X_{(n)}) = \frac{n}{\theta^n} \int_0^\theta x^n dx = \frac{n\theta}{n+1}, \quad E(X_{(n)}^2) = \frac{n}{\theta^n} \int_0^\theta x^{n+1} dx = \frac{n\theta^2}{n+2}.$$

a. Note que

$$E(\bar{X}) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{\theta}{2},$$

de ahí que  $E(\hat{\theta}_{MM}) = \theta$ . De este modo,

$$\text{MSE}(\hat{\theta}_{MM}) = \text{var}(\hat{\theta}_{MM}) = \text{var}(2\bar{X}) = \frac{4}{n^2} \sum_{i=1}^n \text{var}(X_i) = \frac{4}{n} \text{var}(X_1) = \frac{4}{n} \frac{\theta^2}{12} = \frac{\theta^2}{3n}.$$

b. Es sesgo del estimador máximo verosímil para  $\theta$  es dado por:

$$\text{bias}(\hat{\theta}_{ML}, \theta) = E(X_{(n)}) - \theta = \frac{n\theta}{n+1} - \theta = -\frac{\theta}{n+1},$$

mientras que la varianza asume la forma

$$\text{var}(\hat{\theta}_{ML}) = E(X_{(n)}^2) - E^2(X_{(n)}) = \frac{n\theta^2}{n+2} - \frac{n^2\theta^2}{(n+1)^2} = \frac{n\theta^2}{(n+2)(n+1)^2}.$$

De ahí que el MSE para el estimador ML puede ser escrito como:

$$\text{MSE}(\hat{\theta}_{ML}) = \text{var}(\hat{\theta}_{ML}) + \text{bias}^2(\hat{\theta}_{ML}, \theta) = \frac{n\theta^2}{(n+2)(n+1)^2} + \frac{\theta^2}{(n+1)^2} = \frac{2\theta^2}{(n+1)(n+2)}.$$

c. Para comparar  $\hat{\theta}_{MM}$  con  $\hat{\theta}_{ML}$ , considere:

$$\text{MSE}(\hat{\theta}_{MM}) - \text{MSE}(\hat{\theta}_{ML}) = \frac{\theta^2}{3n} - \frac{2\theta^2}{(n+1)(n+2)} = \frac{\theta^2}{3n(n+1)(n+2)}(n^2 - 3n + 2) > 0.$$

De este modo, el estimador ML es mejor que el obtenido por el MM (para cualquier  $n$ ).

4. a. Tenemos

$$\Phi_n(\theta) = \sum_{i=1}^n u_i(\theta),$$

donde  $u_i(\theta) = Y_i - X_i/\theta$ . Notando que  $E\{u_i(\theta)\} = E(Y_i) - E(X_i)/\theta = 0$ , y

$$E\left\{\frac{d u_i(\theta)}{d \theta}\right\} = \frac{1}{\theta^2} E(X_i) = \frac{1}{\theta} E(Y_i).$$

Mientras que  $\text{var}\{u_i(\theta)\} = E\{u_i^2(\theta)\}$ . Por tanto, la función de estimación óptima en  $\mathcal{L}(u_i)$  asume la forma

$$\Psi_n(\theta) = \sum_{i=1}^n \frac{E(Y_i)/\theta}{E\{u_i^2(\theta)\}} u_i(\theta) = \sum_{i=1}^n \frac{E(Y_i)}{E\{u_i^2(\theta)\}} \frac{(Y_i - X_i/\theta)}{\theta}.$$

4. b. Es fácil notar que la información de Godambe para  $\Phi_n(\theta)$  asume la forma

$$\begin{aligned} J_{\Phi}(\theta) &= E\left\{\frac{d \Phi_n(\theta)}{d \theta}\right\} (\text{var}\{\Phi_n(\theta)\})^{-1} E\left\{\frac{d \Phi_n(\theta)}{d \theta}\right\} \\ &= \sum_{i=1}^n E\left\{\frac{d u_i(\theta)}{d \theta}\right\} \left(\sum_{i=1}^n \text{var}\{u_i(\theta)\}\right)^{-1} \sum_{i=1}^n E\left\{\frac{d u_i(\theta)}{d \theta}\right\}. \end{aligned}$$

Usando los resultados obtenidos en la parte **4.a)** y escalando de forma apropiada, obtenemos

$$\begin{aligned} J_{\Phi}(\theta) &= n \left( \frac{1}{n} \sum_{i=1}^n \mathbb{E} \left\{ \frac{d u_i(\theta)}{d \theta} \right\} \right)^2 \left( \frac{1}{n} \sum_{i=1}^n \text{var}\{u_i(\theta)\} \right)^{-1} \\ &= \frac{n \left( \frac{1}{n} \sum_{i=1}^n \mathbb{E}(Y_i) / \theta \right)^2}{\frac{1}{n} \sum_{i=1}^n \mathbb{E}\{u_i^2(\theta)\}}. \end{aligned}$$