

Guía de Ejercicios 2

Profesor: Joaquín Fontbona.

Auxiliares: Catalina Lizana, Fabián Ulloa y Claudio López.

P1. [Hipoteseando] Sean $\beta \in]0, 1[$ y $\theta_0 > 0$ dos constantes que suponemos conocidas. Sean X_1, \dots, X_n variables aleatorias reales i.i.d. cuya distribución tiene la densidad

$$f_{\theta}(x) = \frac{1}{(1 + \beta)\theta} \mathbf{1}_{[-\beta\theta; \theta]}(x),$$

donde $\theta > 0$ es un parámetro desconocido. Queremos probar la hipótesis nula $H_0 : \theta \in]0, \theta_0]$ contra la hipótesis alternativa $H_1 : \theta > \theta_0$ a un nivel $\alpha \in]0, 1[$. El objetivo del ejercicio es construir y estudiar tres tests para estas hipótesis y comparar su potencia.

a) **[Preliminar]** Sean U_1, \dots, U_n variables uniformes i.i.d. en un intervalo $[a, b]$. Demuestre que la función de distribución F de $Z = \max(U_1, \dots, U_n)$ se escribe:

$$F(z) = \begin{cases} 0 & \text{si } z < a, \\ \left(\frac{z-a}{b-a}\right)^n & \text{si } a \leq z \leq b, \\ 1 & \text{si } z > b. \end{cases}$$

El primer test está definido por su región crítica:

$$W_1 = \{(x_1, \dots, x_n) : \max_{1 \leq i \leq n} x_i > c_1\}.$$

b) Suponemos $c_1 \in]0, \theta_0[$. Calcule

$$E_1(\theta) = P_{\theta} \left(\max_{1 \leq i \leq n} X_i > c_1 \right)$$

para todo $\theta > 0$ y demuestre que $\theta \mapsto E_1(\theta)$ es creciente.

Sea $\gamma = (1 + \beta)(1 - \alpha)^{1/n}$. Los valores de β , α y n son tales que $\gamma > 1$.

- c) Dé la expresión del valor crítico c_1 en función de β , γ y θ_0 y verifique que $c_1 \in]0, \theta_0[$. (Recordar que queremos una prueba de nivel α .)
- d) Para $\theta > \theta_0$, sea $\pi_1(\theta)$ la potencia del test 1. Dé la expresión de $\pi_1(\theta)$ en función de θ , β , n y c_1 , luego en función de θ , β , n , γ y θ_0 .
- e) Inspirándose en el test 1, proponga un segundo test utilizando como estadístico de prueba $\min_{1 \leq i \leq n} X_i$. Rehaga las tres preguntas anteriores para este segundo test e indique:
- la región crítica del test, W_2
 - la expresión del valor crítico c_2 en función de γ y θ_0 ,
 - la expresión de la potencia $\pi_2(\theta)$ en función de θ , β , n , γ y θ_0 .
- f) ¿Es alguno de estos tests uniformemente más potente que el otro?

Para el tercer test se utiliza el estadístico de test dado por:

$$T_3 = \max \left(\max_{1 \leq i \leq n} X_i, -\frac{1}{\beta} \min_{1 \leq i \leq n} X_i \right).$$

- g) Sea, para $1 \leq i \leq n$, $Y_i = \max(X_i, -\frac{1}{\beta}X_i)$. Expresa T_3 en función de los Y_i .
- h) Suponemos que el valor crítico del test, denotado c_3 , vive en $]0, \theta_0[$. Para $\theta > 0$, exprese $E_3(\theta) = P(T_3 > c_3)$ en función de la función de distribución F_θ asociada a la densidad f_θ .
- i) Dé la expresión del valor crítico c_3 . Verifique que $c_3 \in]0, \theta_0[$.
- j) Calcule $\pi_3(\theta)$ en función de θ, β, n, γ y θ_0 . Compare los tres tests.

P2. (★) Recordamos la definición de una Ley multinomial de orden K . Sea $N \in \mathbb{N}^*$, $p \in]0, 1[$ tal que $\sum_{i=1}^K p_i = 1$. Llamamos ley multinomial de parámetros (N, p) a la ley de probabilidad en $\{0, 1, \dots, N\}^K$ definida por la función de masa:

$$P(x_1, \dots, x_K) = \begin{cases} \frac{N!}{\prod_{i=1}^K x_i!} \prod_{i=1}^K p_i^{x_i}, & \text{si } (x_1, \dots, x_K) \in \{0, 1, \dots, N\}^K \text{ tal que } \sum_{i=1}^K x_i = N, \\ 0, & \text{en otro caso.} \end{cases}$$

Denotamos $X \sim M(N, p)$.

Recordamos también la definición de una ley de Dirichlet de orden K . Sea $a = (a_1, \dots, a_K) \in \mathbb{R}_+^K$. Llamamos ley de Dirichlet de parámetro a a la ley de probabilidad con soporte $S = \{x \in [0, 1]^K : \sum_{i=1}^K x_i = 1\}$, definida por la densidad:

$$p(x_1, \dots, x_K) = \begin{cases} \frac{1}{\beta(a)} \prod_{i=1}^K x_i^{a_i-1}, & \text{si } (x_1, \dots, x_K) \in S, \\ 0, & \text{en otro caso.} \end{cases}$$

Denotamos esta ley como $\text{Dir}(a)$. La ley de Dirichlet de orden 2 es la ley Beta, $\text{Dir}(a_1, a_2) = \text{Beta}(a_1, a_2)$.

- a) Sin realizar el cálculo, indicar cómo determinar la función $\beta(a)$. Se supone conocida para el resto del ejercicio.
- b) Sea Y una variable aleatoria que sigue una ley multinomial de orden K , $K \geq 3$, y de parámetros (N, θ) , donde N es conocido e $\theta = (\theta_1, \dots, \theta_K)$ es desconocido. Sea $y = (y_1, \dots, y_K)$ una observación de la variable Y . Nos encontramos en el marco de la estimación bayesiana para θ . Suponemos la distribución a priori $\pi = \text{Dir}(a)$, con $a = (a_1, \dots, a_K) \in \mathbb{R}_+^K$. Determinar la ley de la distribución a posteriori $p(\theta|y)$.
- c) 1) Demuestre que si $(X_1, \dots, X_{K-1}, X_K)$ sigue una ley de Dirichlet de parámetros $(a_1, \dots, a_{K-1}, a_K)$, entonces $(X_1, \dots, X_{K-2}, X_{K-1} + X_K)$ sigue una ley de Dirichlet de parámetros $(a_1, \dots, a_{K-2}, a_{K-1} + a_K)$.
- 2) Denotamos $a_r = \sum_{i=3}^K a_i$ y $y_r = \sum_{i=3}^K y_i$. Deducir de la pregunta anterior que $p(\theta_1, \theta_2|y) \propto \theta_1^{a_1+y_1-1} \theta_2^{a_2+y_2-1} (1 - \theta_1 - \theta_2)^{a_r+y_r-1}$.

P3. (★) [¿Y si no puedo invertir?] Sea X una variable aleatoria con valores en \mathbb{R}^p e Y una variable aleatoria con valores en \mathbb{R} . Suponemos que la ley de X es conocida. Sean N pares independientes de observaciones $(x_i, y_i)_{1 \leq i \leq N}$. Nos interesamos en la regresión lineal de Y dado X :

$$Y = \beta_0 + \beta^T X + \xi, \text{ donde } \xi \sim \mathcal{N}(0, \sigma^2) \text{ y es independiente de } X$$

Suponemos que $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = 0$ e $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i = 0$. ¿Podemos ponernos siempre bajo este supuesto?

Denotamos x_{ij} como la j -ésima componente de las variables explicativas de la muestra i , x_i . Definimos la *matriz de design* del problema de regresión y el vector de *labels* como:

$$X = \begin{pmatrix} x_{11} & \dots & x_{1p} \\ \vdots & \ddots & \vdots \\ x_{N1} & \dots & x_{Np} \end{pmatrix} \text{ y } Y = \begin{pmatrix} y_1 \\ \vdots \\ y_N \end{pmatrix}$$

- a) Recuerde el problema de estimación de (β_0, β) en este contexto. Demuestre que bajo nuestros supuestos, necesariamente $\beta_0 = 0$. Podemos asumir esto para los items siguientes.
- b) Si $N > p$ recuerde cómo es la solución explícita al problema de los mínimos cuadrados.
- c) Sea $p > N$. En este caso, la regresión lineal clásica no es posible (¿por qué?). Para solucionar este problema consideraremos el problema de *regresión ridge* (también se le dice *con penalización L2*). Es decir, para $\lambda > 0$, buscaremos:

$$\hat{\beta}_{\text{ridge}} \in \arg \min_{\gamma} \|X\gamma - Y\|_2^2 + \lambda \|\gamma\|_2^2$$

Explique por qué esto nos permite resolver el problema y encuentre la solución explícita (demostrando, de paso, que es única).

P4. [¿Regresión Lineal?] Queremos explicar la relación entre una v.a. Y que toma valores en $\{0, 1\}$ (e.g. para una *clasificación binaria*) y un vector de covariables X a valores en \mathbb{R}^{p+1} (con la primera coordenada estando fija en 1). Aplicar un modelo de regresión lineal clásico, $Y_i = \beta^T X_i + \varepsilon_i$ (con ε_i centrados), NO parece ser la mejor idea, pues *el lado derecho es, en principio, no acotado*.

Lo que sí podemos hacer es *recurrir a los modelos lineales generalizados*. Por ejemplo, consideremos la función **logit**: $]0, 1[\rightarrow \mathbb{R} : \pi \mapsto \log\left(\frac{\pi}{1-\pi}\right)$ (cuya inversa es la función *sigmoide*); y modelaremos la relación entre los Y y los X como: $\pi_i := \mathbb{P}(Y_i = 1 | X_i) = \mathbf{logit}^{-1}(\beta_0 + \beta^T X_i)$. Es decir: $\mathbf{logit}(\mathbb{E}[Y|X]) = \beta_0 + \beta^T X$ (es *casi* un modelo lineal).

Sea $(X_1, Y_1), \dots, (X_n, Y_n)$ una muestra i.i.d. de estas v.a.s. Asumimos que los $(X_i)_i$ son todos fijos:

- a) Demuestre que la log-verosimilitud (condicional) de la muestra en función de β se escribe como:

$$\ell(\beta | (X_i, Y_i)_i) = \sum_{i=1}^n [Y_i X_i^T \beta - \log(1 + \exp(X_i^T \beta))]$$

- b) No existe una expresión analítica para el EMV. Se debe utilizar un algoritmo de optimización (*Newton-Raphson*), para aproximar el óptimo mediante una secuencia $(\beta^{(k)})_{k \in \mathbb{N}}$ dada por:

$$\beta^{(k+1)} = \beta^{(k)} - [H(\beta^{(k)})]^{-1} U(\beta^{(k)})$$

donde $S(\beta^{(k)}) = \frac{\partial \ell}{\partial \beta}$ y $H(\beta^{(k)})$ es tal que $H(\beta^{(k)})_{i,j} = \frac{\partial^2 \ell}{\partial \beta_i \partial \beta_j}$.

Dé una expresión explícita de $U(\beta^{(k)})$ y $H(\beta^{(k)})$ en el contexto del modelo logístico.

P5. Consideremos $(x_1, Y_1), \dots, (x_n, Y_n) \in \mathbb{R}^p \times \mathbb{R}$ observaciones (ejemplos) en las que se supone que siguen un modelo lineal de la forma:

$$Y_i = \beta_0 + \beta^T x_i + \epsilon_i, \quad (1)$$

donde $\epsilon_1, \dots, \epsilon_n \sim N(0, \sigma^2)$. Se supone que los x_i son deterministas, $\beta_0 \in \mathbb{R}$, $\beta \in \mathbb{R}^p$ son parámetros desconocidos, y $\sigma^2 > 0$ se supone conocido. Para simplificar las notaciones, se incluirá un “1” al principio del vector de covariables, para poder escribir el modelo de la forma:

$$Y_i = \beta^T x_i + \epsilon_i, \quad (2)$$

donde el vector β ahora tiene tamaño $p + 1$ (y β_0 corresponde a su primera coordenada). Definimos la *matriz de design* A como:

$$A = \begin{pmatrix} x_1^T \\ \vdots \\ x_n^T \end{pmatrix} \in \mathbb{R}^{n \times (p+1)}, \quad (3)$$

y suponemos que A tiene rango $p + 1$.

- Demuestre que $A^T A$ es definida positiva. Recuerde la expresión del estimador de mínimos cuadrados, que se denotará como $\hat{\beta}$, y justifique que está bien definido.
- Sea R_n el riesgo empírico, que está dado por:

$$\hat{R}_n = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{\beta}^T x_i)^2$$

Demuestre que

$$\hat{R}_n = \frac{1}{n} Y^T Q Y$$

donde Q es una matriz de un proyección ortogonal que usted debe determinar (en particular, debe explicitar su imagen y su rango).

- Demuestre que

$$\mathbb{E}[\hat{R}_n] = \sigma^2 \left(1 - \frac{p+1}{n} \right)$$

P6. (★) [Triangulando] Se miden los ángulos $\theta_1, \theta_2, \theta_3$ de un triángulo, obteniéndose las observaciones y_1, y_2, y_3 . Las mediciones tienen errores normales, centrados, de varianza común σ^2 e independientes. Esto permite plantear el modelo lineal $y_i = \theta_i + \varepsilon_i$ ($i = 1, 2, 3$) sujeto a la restricción $\theta_1 + \theta_2 + \theta_3 = \pi$.

- Muestre que el estimador de mínimos cuadrados de θ_i , tomando en cuenta la restricción, está dada por:

$$\hat{\theta}_i = y_i - \left(\bar{y} - \frac{\pi}{3} \right)$$

- Se sospecha que el triángulo tiene dos posibles combinaciones de ángulos: $(\pi/3, \pi/4, 5\pi/12)$ y $(\pi/2, \pi/3, \pi/6)$. Escriba en detalle el modelo paramétrico del problema y plantee, en términos de los parámetros del problema, y las hipótesis H_0 y H_1 .
- Suponga σ conocido y desarrolle el Test de Neyman Pearson de nivel α , explicitando la región crítica.

P7. (★) [Testeando Cosillas] Considere un modelo en el que

$$Y_i = \begin{cases} x_i \beta_1 + \varepsilon_i, & \text{si } i = 1, \dots, n_1, \\ x_i \beta_2 + \varepsilon_i, & \text{si } i = n_1 + 1, \dots, n_1 + n_2 = n, \end{cases}$$

con $\varepsilon_1, \dots, \varepsilon_n$ i.i.d. de $N(0, \sigma^2)$ y variables independientes x_1, \dots, x_n tomadas como constantes conocidas.

- Escriba este modelo como un modelo lineal.
- Encuentre estimadores insesgados para β_1 y β_2 .

c) Considere la cantidad $\xi = X^T \beta$, siendo X alguna matriz de diseño y $\beta = (\beta_1, \beta_2)^T$ y

$$s^2 = \frac{\|Y - \xi\|^2}{n - 2}$$

¿qué distribución sigue s^2 ?

Ahora se decide llevar a cabo el siguiente test de nivel $1 - \alpha$:

$$H_0: \beta_1 = \beta_2 \text{ v/s } H_1: \beta_1 \neq \beta_2$$

Para ello asumamos H_0 , denotando a β_0 el parámetro que tiene igual valor que β_1 y β_2 y siga el siguiente esquema:

- d) Sea X_0 la matriz de diseño bajo H_0 y $\xi = X_0^T \beta_0$, calcule $\|\xi - \xi_0\|^2$. ¿Qué interpretación le da a esta cantidad? ¿Qué pasaría con esta cantidad si H_0 fuera cierta?
- e) Con s^2 y $\|\xi - \xi_0\|^2$ construya un estadístico que defina el p-value del test y su región crítica de rechazo, explicité ambas. *Indicación: Si $S_1 \sim \chi_{d_1}^2$, $S_2 \sim \chi_{d_2}^2$, entonces*

$$\frac{S_1/d_1}{S_2/d_2} \sim F_{d_1, d_2}$$

donde F_{d_1, d_2} es ley Fisher de grados de libertad d_1, d_2 , asuma conocida esta distribución para todo d_1, d_2 .

P8. (★) [Bayesianismo] Sea $X_n = (X_1, \dots, X_n)$ una muestra de n observaciones independientes e idénticamente distribuidas según la ley de Poisson con parámetro $\theta > 0$.

- a) Demuestre que el estimador de máxima verosimilitud de θ , denotado como $\hat{\theta}_n^{\text{EMV}}$, está bien definido y dé su expresión.
- b) Verifique que el vector de *score* está centrado, calcule la cota de Cramér-Rao y demuestre que $\hat{\theta}_n^{\text{EMV}}$ es un estimador insesgado eficiente.

Ahora, el parámetro desconocido θ se distribuye a priori como $\text{Gamma}(\alpha_0, \beta_0)$, donde α_0 y β_0 son números reales estrictamente positivos dados:

$$\pi(\theta) \propto (\beta_0 \theta)^{\alpha_0 - 1} e^{-\beta_0 \theta} \mathbf{1}_{\{\theta > 0\}}.$$

- c) Demuestre que la familia de leyes gamma es conjugada para el parámetro θ .
- d) Determine el estimador bayesiano óptimo para la pérdida cuadrática, denotado como $\hat{\theta}_n^{\text{Bayes}}$. (Se puede utilizar sin demostración el resultado general visto en clase).

Volviendo a un enfoque “frecuentista” para las cuatro últimas preguntas, lo que significa que nos interesamos en las propiedades de los estimadores $\hat{\theta}_n^{\text{EMV}}$ y $\hat{\theta}_n^{\text{Bayes}}$ para un $\theta > 0$ fijo.

- e) Demuestre que el estimador bayesiano $\hat{\theta}_n^{\text{Bayes}}$ es sesgado independientemente de la elección de los parámetros α_0 y β_0 , pero asintóticamente insesgado.
- f) Calcule el riesgo cuadrático de cada uno de los dos estimadores, $\hat{\theta}_n^{\text{EMV}}$ y $\hat{\theta}_n^{\text{Bayes}}$.
- g) Demuestre que ninguno de los dos estimadores, $\hat{\theta}_n^{\text{EMV}}$ y $\hat{\theta}_n^{\text{Bayes}}$, es preferible al otro en términos de riesgo cuadrático.
- h) Demuestre que el estimador bayesiano $\hat{\theta}_n^{\text{Bayes}}$ es fuertemente consistente y asintóticamente gaussiano, especificando su varianza asintótica. Compare con las propiedades asintóticas de $\hat{\theta}_n^{\text{EMV}}$. (Indicación: observe que $\hat{\theta}_n^{\text{Bayes}}$ tiene la forma $a_n + b_n X_n$, con $a_n = O(1/n)$ y $b_n = 1 + O(1/n)$).

P9. [Esto NO es Lineal] En este ejercicio, suponemos que observamos n variables aleatorias:

$$Y_i = f(x_i) + \varepsilon_i, \quad 1 \leq i \leq n, \quad (1)$$

donde los puntos x_i son deterministas, espaciados regularmente entre $1/n$ y 1:

$$x_i = \frac{i}{n}, \quad (2)$$

los ε_i son i.i.d. $N(0, \sigma^2)$ con varianza $\sigma^2 > 0$ conocida, y $f : [0, 1] \rightarrow \mathbb{R}$ tiene la forma:

$$f(x) = a_0 + \sum_{k=1}^K a_k \cos(2\pi kx), \quad (3)$$

con a_0, a_1, \dots, a_K siendo parámetros reales desconocidos.

- a) Bajo estas hipótesis, escriba el modelo (1)–(3) como un modelo lineal gaussiano $Y_i = (X\beta)_i + \varepsilon_i$ especificando X y β .
- b) Suponemos ahora que $K+1 \leq n$. Verifique que el estimador de mínimos cuadrados $\hat{\beta} = (\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_K)$ de β está bien definido y demuestre que es igual a:

$$\begin{cases} \hat{\beta}_0 = \frac{1}{n} \sum_{i=1}^n Y_i = \bar{Y}_n, \\ \hat{\beta}_k = \frac{2}{n} \sum_{i=1}^n Y_i \cos\left(\frac{2\pi ki}{n}\right). \end{cases}$$

- c) De ello, obtenga un estimador $\hat{\mu}$ de $\mu = (f(i/n))_{1 \leq i \leq n}$ y proponga finalmente un estimador \hat{f} de la función f .
- d) Calcule la esperanza de la suma de los residuos al cuadrado normalizados $r_n = \frac{1}{n} \mathbb{E} \left[\sum_k (Y - X\hat{\beta})_k^2 \right]$. ¿Qué sucede cuando K está fijo y n tiende a infinito?
- e) Suponemos ahora que $n = K + 1$. Dé el valor de r_n . ¿Qué se puede decir de la función \hat{f} en los puntos $x_i = i/n, 1 \leq i \leq n$?