

Pauta Aux 2

①

P1 | $X_1, \dots, X_n \sim \text{Geom}(p)$ $p \in (0, 1]$ desconocido

PMF: $f(k; p) = (1-p)^{k-1} p \quad \forall k \in \mathbb{N}_*$

a) $\rightarrow$ método de los momentos

Si $X \sim \text{Geom}(p) \Rightarrow E[X] = \frac{1}{p}$ tenemos una forma de estimar p :

Utilizamos $\hat{E}(X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n X_i =: \bar{X} = \frac{1}{p}$ la esperanza empírica de la muestra $(X_1, \dots, X_n)$, y por tanto

$$\boxed{\hat{p}_{\text{mom}} = \frac{1}{\bar{X}}}$$

b) $\rightarrow$ Calcular estimador máxima verosimilitud

La verosimilitud es $\mathcal{L}(p|x) = \prod_k f(x_k; p) = \prod_k (1-p)^{x_k-1} p$
 $= (1-p)^{\sum x_k - n} p^n = (1-p)^{n\bar{X} - n} p^n$

$$\Rightarrow \mathcal{L}(p|x) = (1-p)^{n\bar{X} - n} p^n$$

La log-verosimilitud entonces es:

$$\ell(p|x) = \ln \mathcal{L}(p|x) = n(\bar{X} - 1) \ln(1-p) + n \ln p$$

Derivémoslo w.r a p en el intervalo $(0, 1)$

$$\frac{\partial}{\partial p} \ell(p|x) = n(\bar{X} - 1) \frac{-1}{1-p} + n \frac{1}{p}$$

imponiendo $\frac{\partial}{\partial p} \ell(p|x) \stackrel{!}{=} 0$ se tiene que:

$$n \frac{1}{p} = n(\bar{X} - 1) \frac{1}{1-p} \Rightarrow (1-p) = \bar{X}p - p \Rightarrow \boxed{\hat{p}_{\text{MLE}} = \frac{1}{\bar{X}}}$$

c) Aquí hubo una errata en el aux. para verlo, empecemos analizando lo siguiente:

$$E[\bar{X}] = E\left[\frac{1}{n} \sum_{i=1}^n X_i\right] = \frac{1}{n} \sum_{i=1}^n E[X_i] = \frac{1}{n} \sum_{i=1}^n \frac{1}{p} = \frac{1}{p}$$

No tenemos que la función $x \mapsto \frac{1}{x}$ es convexa, por tanto, por la desig. de Jensen:

$$E[\hat{p}_{\text{MLE}}] = E\left[\frac{1}{\bar{X}}\right] > \frac{1}{E[\bar{X}]} = p \quad \text{pues } \frac{\partial^2}{\partial x^2} \left[\frac{1}{x}\right] = \frac{2}{x^3} > 0 \quad \forall x > 0$$

$= p$ y por tanto es sesgado.

P2 $X_1, \dots, X_n \sim \text{Unif}[\theta, \theta+1]$ con $\theta \in \mathbb{R}$ desconocido

Recordemos que su función de distr. es

$$f(x; a, b) = \frac{1}{b-a} \mathbb{1}_{x \in [a, b]} \quad \forall x \in \mathbb{R}$$

Dada $(x_1, \dots, x_n)$ muestra, la verosimilitud es:

$$\mathcal{L}(\theta | x) = \prod_{i=1}^n f(x_i; \theta, \theta+1) = \prod_{i=1}^n \mathbb{1}_{x_i \in [\theta, \theta+1]}$$

Recordando que si p y q son dos proposiciones, entonces $\mathbb{1}_p \cdot \mathbb{1}_q = \mathbb{1}_{p \wedge q}$ así:

$$\mathcal{L}(\theta | x) = \prod_{i=1}^n \mathbb{1}_{x_i \in [\theta, \theta+1]} = \mathbb{1}_{x_1, \dots, x_n \in [\theta, \theta+1]}$$

Sin embargo, hay que pensar en la verosimilitud como fn de θ , y que los x_i están fijos, o "inyectados" en la verosimilitud.

Tratemos de trabajar esa expresión:

$$x_1, \dots, x_n \in [\theta, \theta+1] \Leftrightarrow \forall k=1:n \quad \theta \leq x_k \wedge \theta+1 \geq x_k$$

$$\Leftrightarrow \theta \leq \min_k x_k \wedge \theta+1 \geq \max_k x_k$$

$$\Leftrightarrow \theta \in [\max_k x_k - 1, \min_k x_k]$$

Entonces:

$$\mathcal{L}(\theta | x) = \mathbb{1}_{x_1, \dots, x_n \in [\theta, \theta+1]} = \mathbb{1}_{\theta \in [\max_k x_k - 1, \min_k x_k]}$$

y por tanto

$$\arg \max_{\theta} \mathcal{L}(\theta | x) = [\max_k x_k - 1, \min_k x_k]$$

P3)

- a) N pob. total
 K se capturan y marcan
 n se capturan dsps de un mes

$P_N(k)$ prob. de que dsps de un mes k de los n estén marcados

$$P_N(k) = \frac{\binom{K}{k} \binom{N-K}{n-k}}{\binom{N}{n}}$$

formas de sacar $n-k$ no marcados de entre $N-K$
 formas de sacar n animales de entre N animales.
 formas de sacar k marcados entre K animales marcados.

Esto es: $P_N \sim \text{Hiper Geom}(N, \tilde{K}, \tilde{n})$ (con $\tilde{K}$ y $\tilde{n}$ "fijos", pero N es el parámetro de los modelos)

$$b) \frac{P_N(k)}{P_{N-1}(k)} = \frac{\binom{K}{k} \binom{N-K}{n-k}}{\binom{N}{n}} \frac{\binom{N-1}{n}}{\binom{K}{k} \binom{N-1-K}{n-k}} = \frac{\binom{N-1}{n}}{\binom{N}{n}} \frac{\binom{N-K}{n-k}}{\binom{N-1-K}{n-k}}$$

$$= \frac{(N-1)!}{N!} \cdot \frac{(N-K)!}{(N-K-1)!} \cdot \frac{(N-1-n)!}{(N-n)!} \cdot \frac{(N-K-n+k)!}{(N-K-n+k-1)!}$$

$$= \frac{1}{N} \cdot (N-n) \cdot (N-K) \cdot \frac{1}{N-K-n+k} = \frac{(N-K)(N-n)}{N(N-K-n+k)}$$

$$P_N(k) \geq P_{N-1}(k) \Leftrightarrow (N-K)(N-n) \geq N(N-K-n+k)$$

$$\Leftrightarrow \cancel{N^2} - \cancel{KN} - \cancel{nN} + nK \geq \cancel{N^2} - \cancel{NK} - \cancel{nN} + Nk$$

$$\Leftrightarrow nK \geq Nk \Leftrightarrow N \leq \frac{nK}{k}$$

∴ $P_N(k)$ creciente con $N \in \{0, \dots, \lfloor \frac{nK}{k} \rfloor\}$
 decreciente en $N \in \{\lfloor \frac{nK}{k} \rfloor + 1, \dots\}$
 $\Rightarrow \hat{N}_{MLE} = \lfloor \frac{nK}{k} \rfloor$

$$\begin{matrix} K=10 \\ n=5 \\ k=1 \end{matrix} \left\{ \hat{N}_{MLE} = 50 \right.$$

La interpretación es que, digamos, originalmente habrían $N = 100$ animales, pero se tomó una muestra de $K = 10$ delfines, entonces en la segunda vez se hará un re-escalamiento de K , por medio del segundo vistazo. Este factor de reescalamiento de K es $\frac{n}{k}$, que se

C) Aquí: $K = 10$, $n = 5$, $k = 1$

$$\hat{N}_{MLE} = K \cdot \frac{n}{k} = 10 \cdot \frac{5}{1} = 50.$$

P4) $X_1, \dots, X_n \sim \text{Gamma}(k, \lambda)$ con, $k > 0$ y $\lambda > 0$ desconocidos
 su pdf: $f(x; k, \lambda) = \frac{1}{\Gamma(k)\lambda^k} x^{k-1} e^{-\frac{x}{\lambda}} \mathbb{1}_{x>0}$

Se puede calcular que para $X \sim \text{Gamma}(k, \lambda)$, su función generadora de momentos es

$$M_X(t) = \mathbb{E}[e^{tX}] = (1 - \lambda t)^{-k} \quad \text{para } t < \frac{1}{\lambda}$$

Derivando:

$$\frac{d}{dt} M_X(t) = (1 - \lambda t)^{-k-1} (-k) \cdot (-\lambda) = \lambda k (1 - \lambda t)^{-k-1}$$

$$\frac{d^2}{dt^2} M_X(t) = \lambda^2 k (1 - \lambda t)^{-k-2} (-k-1) (-\lambda) = \lambda^2 k (k+1) (1 - \lambda t)^{-k-2}$$

Generando los momentos:

$$\mathbb{E}[X] = \frac{d}{dt} M_X(t) \Big|_{t=0} = \lambda k$$

$$\mathbb{E}[X^2] = \frac{d^2}{dt^2} M_X(t) \Big|_{t=0} = \lambda^2 k (k+1)$$

Ahora tenemos un sistema de Ecs. para λ y k . usando la esperanza empírica:

$$\frac{1}{n} \sum_{i=1}^n x_i =: \bar{x} = \lambda k$$

$$\frac{1}{n} \sum_{i=1}^n x_i^2 =: \overline{x^2} = \lambda^2 k (k+1)$$

Notemos que

$$\overline{x^2} = \lambda^2 k (k+1) = \frac{\lambda^2 k^2}{\frac{\bar{x}}{\lambda}} + \frac{\lambda^2 k}{\frac{\bar{x}}{\lambda}} = \overline{x^2} + \lambda \bar{x} \Rightarrow \hat{\lambda}_{\text{MOM}} = \frac{\overline{x^2} - \bar{x}^2}{\bar{x}}$$

$$\text{Además, } \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \left(\frac{1}{n} \sum_{i=1}^n x_i\right)^2 = \overline{x^2} - \bar{x}^2$$

$$\Rightarrow \hat{\lambda}_{\text{MOM}} = \frac{\hat{\sigma}^2}{\bar{x}}$$

$$\text{Y tenemos que } \bar{x} = \lambda k, \Rightarrow \hat{k}_{\text{MOM}} = \frac{\bar{x}}{\hat{\lambda}} = \frac{\bar{x}}{\frac{\hat{\sigma}^2}{\bar{x}}} = \frac{\bar{x}^2}{\hat{\sigma}^2}$$

$$\therefore \hat{\lambda}_{\text{MOM}} = \frac{\hat{\sigma}^2}{\bar{x}} \quad \hat{k}_{\text{MOM}} = \frac{\bar{x}^2}{\hat{\sigma}^2}$$

b) Asumiendo que tenemos k fijo, tenemos que la familia de modelos paramétricos es:

$$\mathcal{U}_\theta = \{ \text{Gamma}(\tilde{k}, \lambda) \mid \lambda \in \mathbb{R}_+ = \Theta \}$$

y la verosimilitud en este caso es:

$$\begin{aligned} \mathcal{L}(\lambda | x) &= \prod_{i=1}^n f(x_i; \tilde{k}, \lambda) \quad / \text{denotaré } \tilde{k} \text{ por } k \text{ por simplicidad (flojera)} \\ &= \prod_{i=1}^n \frac{1}{\Gamma(k) \lambda^k} x_i^{k-1} e^{-x_i/\lambda} \quad \text{pues } \forall i, x_i > 0 \text{ y no entra } \lambda \\ &= \frac{1}{\Gamma(k)^n} \lambda^{-nk} (\prod x_i)^{k-1} e^{-\sum x_i / \lambda} \\ &= \frac{(\prod x_i)^{k-1}}{\Gamma(k)^n} \lambda^{-nk} e^{-\frac{n\bar{x}}{\lambda}} \end{aligned}$$

y la log-verosimilitud es:

$$\ell(\lambda | x) = \underbrace{(k-1) \sum \log x_i - n \log \Gamma(k)}_{\text{cte c/r a } \lambda} - nk \log \lambda - \frac{n\bar{x}}{\lambda}$$

Derivamos!

$$\frac{\partial}{\partial \lambda} \ell(\lambda | x) = -nk \frac{1}{\lambda} + \frac{n\bar{x}}{\lambda^2}$$

Imponemos $= 0$

$$-\frac{nk}{\lambda} + \frac{n\bar{x}}{\lambda^2} \stackrel{\lambda > 0}{=} 0 \Leftrightarrow -k + \frac{\bar{x}}{\lambda} = 0 \Leftrightarrow \lambda = \frac{\bar{x}}{k}$$

y por tanto

$$\hat{\lambda}_{MLE} = \frac{\bar{x}}{\tilde{k}}$$

P5) $X_1, \dots, X_n \sim \text{Unif}[a, b]$ $a < b$ desconocidos

Se sabe que los primeros dos momentos de una uniforme son:

$$E[U] = \frac{a+b}{2}$$

$$E[U^2] = \frac{a^2 + ab + b^2}{3}$$

(basta integrar las funciones, puede ser un ejercicio para desempolvar las habilidades de integración)

Entonces planteamos:

$$\frac{1}{n} \sum_{i=1}^n x_i =: \bar{x} = \frac{a+b}{2} \quad (1)$$

$$\frac{1}{n} \sum_{i=1}^n x_i^2 =: \overline{x^2} = \frac{a^2 + ab + b^2}{3} \quad (2)$$

De (1) tenemos que:

$$a+b = 2\bar{x} \Rightarrow a = 2\bar{x} - b \quad (3)$$

Reemplazando (3) en (2):

$$\begin{aligned} 3\overline{x^2} &= (2\bar{x} - b)^2 + (2\bar{x} - b)b + b^2 = 4\bar{x}^2 - 4b\bar{x} + b^2 + 2\bar{x}b - b^2 + b^2 \\ &= b^2 - 2b\bar{x} + \bar{x}^2 + 3\bar{x}^2 = (b - \bar{x})^2 + 3\bar{x}^2 \end{aligned}$$

$$\text{Así: } (b - \bar{x})^2 = 3(\overline{x^2} - \bar{x}^2) = 3\hat{\sigma}^2 \quad (4) \quad \left(\begin{array}{l} \text{Recordar que} \\ \hat{\sigma}^2 = \overline{x^2} - \bar{x}^2 \\ = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \end{array} \right)$$

Reemplazando (3) en (4):

$$(a - \bar{x})^2 = 3\hat{\sigma}^2$$

$$\text{Así, tenemos que} \quad \begin{aligned} b - \bar{x} &= \pm \sqrt{3\hat{\sigma}^2} \\ a - \bar{x} &= \pm \sqrt{3\hat{\sigma}^2} \end{aligned}$$

Pero $a < b$, así que:

$$\begin{aligned} \hat{a}_{\text{mom}} &= \bar{x} - \sqrt{3\hat{\sigma}^2} \\ \hat{b}_{\text{mom}} &= \bar{x} + \sqrt{3\hat{\sigma}^2} \end{aligned} \quad (5)$$

Tratemos de interpretarlo. Sabemos que $\hat{\sigma}^2$ tratará de estimar la varianza, la cuál es:

$$\hat{\sigma}^2 \approx \frac{1}{12} (b-a)^2$$

Así que si lo reemplazamos en (5)

$$\hat{a} \approx \bar{x} - \sqrt{3 \frac{(b-a)^2}{12}} = \bar{x} - \sqrt{\frac{(b-a)^2}{4}} = \bar{x} - \frac{b-a}{2}$$

$$\hat{b} \approx \bar{x} + \frac{b-a}{2}$$

Así que, tomando desde la mitad, el factor $\sqrt{3\hat{\sigma}^2}$ te trata de decir que vayas la longitud del intervalo $(b-a)$ y le restes la mitad, mientras que para b sería sumarle la mitad.

b) Para la máxima verosimilitud, hacemos una estrategia como en la P2):

$$\mathcal{L}(a, b; x) = \prod \frac{1}{b-a} \mathbb{1}_{x_i \in [a, b]} = (b-a)^{-n} \mathbb{1}_{x_1, \dots, x_n \in [a, b]}$$

Vemos que: $x_1, \dots, x_n \in [a, b]$

$$\Leftrightarrow \forall i \ a \leq x_i \wedge b \geq x_i$$

$$\Leftrightarrow a \leq \min_k x_k \wedge b \geq \max_k x_k$$

Entonces

$$\mathcal{L}(a, b; x) = (b-a)^{-n} \cdot \mathbb{1}_{a \leq \min_k x_k} \cdot \mathbb{1}_{b \geq \max_k x_k}$$

Notemos que si fijamos un $\tilde{a} \leq \min_k x_k$, $\mathcal{L}(\tilde{a}, b; x)$ es decreciente en b , con un máximo en $\hat{b} = \max_k x_k$. Si ahora fijamos $\hat{b} = \max_k x_k$, $\mathcal{L}(a, \hat{b}; x)$ es creciente con un tope en $\hat{a} = \min_k x_k$. Por tanto

$$\begin{aligned} \hat{b}_{MLE} &= \max_k x_k \\ \hat{a}_{MLE} &= \min_k x_k \end{aligned}$$

Estos estimadores tienen sentido, pues si tenemos muchas muestras, el $\max_k x_k$ se acerca al valor de b , al igual que $\min_k x_k$ lo hará al parámetro a .

