

Ex 1

(1)

1) La vraisemblance de (x_1, \dots, x_n) s'écrit

$$f(x_1, \dots, x_n; \theta) = \prod_{i=1}^n \left[\theta(1-\theta)^{x_i-1} \right] = \theta^n (1-\theta)^{\sum_{i=1}^n x_i - n}$$

et son logarithme est

$$\ln L(x_1, \dots, x_n; \theta) = n \ln \theta + (\sum x_i - n) \ln(1-\theta)$$

dont on peut étudier les variations


$$\frac{\partial \ln L}{\partial \theta} \geq 0 \Leftrightarrow \frac{n}{\theta} - \frac{\sum x_i - n}{1-\theta} \geq 0$$

Puisque $\theta \in]0, 1[$, on a $\theta > 0$ et $1-\theta > 0$ d'où en multipliant par $\theta(1-\theta)$

$$\frac{\partial \ln L}{\partial \theta} \geq 0 \Leftrightarrow n(1-\theta) - \theta(\sum x_i - n) \geq 0 \Leftrightarrow \theta \leq \frac{n}{\sum x_i} = \frac{1}{\bar{x}}$$

On a donc le tableau de variations suivant

avec $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$



ce qui montre que $\theta = \frac{1}{\bar{x}}$ est le maximum global unique de la log-vraisemblance et donc de la vraisemblance.

2) L'estimateur $\hat{\theta}_{MV}$ est asymptotiquement sans biais, convergent et asymptotiquement efficace. Par contre, l'étude des propriétés de $\hat{\theta}_{MV}$ pour n fini est délicate. En utilisant le principe d'invariance fonctionnelle, on obtient

$$\hat{a}_{MV} = \frac{1}{\hat{\theta}_{MV}} = \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

Les propriétés de cet estimateur sont simples à étudier puisque

$$E[\hat{a}_{MV}] = \frac{1}{n} \sum_{i=1}^n E(x_i) = a \Rightarrow \hat{a}_{MV} \text{ non biaisé}$$

$$\text{Var}[\hat{a}_{MV}] = \frac{\text{Var}(x_i)}{n} = \frac{1-\theta}{n\theta^2} = \frac{1-\frac{1}{a}}{\frac{n}{a^2}} = \frac{a(a-1)}{n}$$

x_1, \dots, x_n ind
 Biais $(\hat{a}_{MV}) = 0$
 $\text{Var}[\hat{a}_{MV}] \rightarrow 0$
 $n \rightarrow +\infty$

\Rightarrow donc l'estimateur \hat{a}_{MV} est convergent

3) Efficacité

(2)

La borne de Cramér-Rao pour un estimateur non biaisé de a est

$$BCR = \frac{[1 + b'(a)]^2}{-E\left[\frac{\partial^2 \ln L}{\partial a^2}\right]} = \frac{-1}{E\left[\frac{\partial^2 \ln L}{\partial a^2}\right]}$$

La vraisemblance peut se réécrire en fonction de a de la manière suivante

$$L(x_1, \dots, x_n; a) = \frac{1}{a^n} \left(1 - \frac{1}{a}\right)^{\sum x_i - n}$$

D'où

$$\ln L = -n \ln a + (\sum x_i - n) \ln \left(1 - \frac{1}{a}\right)$$

$$\frac{\partial \ln L}{\partial a} = -\frac{n}{a} + \frac{\sum x_i - n}{1 - \frac{1}{a}} \left(\frac{1}{a^2}\right) = -\frac{n}{a} + \frac{\sum x_i - n}{a^2 - a}$$

$$\frac{\partial^2 \ln L}{\partial a^2} = \frac{n}{a^2} + (\sum x_i - n) \left[\frac{-(2a-1)}{a^2(a-1)^2} \right]$$

Mais $E[\sum x_i - n] = n E[x_i] - n = na - n = n(a-1)$, d'où

$$E\left[\frac{\partial^2 \ln L}{\partial a^2}\right] = \frac{n}{a^2} + \frac{(1-2a)n}{a^2(a-1)} = \frac{n}{a^2(a-1)} [a-1 + 1-2a] = \frac{-n}{a(a-1)}$$

d'où la borne

$$\boxed{BCR = \frac{a(a-1)}{n}}$$

On en déduit que l'estimateur \hat{a}_{MV} est l'estimateur efficace de a

4) D'après la loi de Bayes, on a

$$\begin{aligned} P(\theta | x_1, \dots, x_n) &\propto P(x_1, \dots, x_n | \theta) P(\theta) \\ &\propto \theta^n (1-\theta)^{\sum x_i - n} \times \theta^{\alpha-1} (1-\theta)^{\beta-1} \\ &\propto \theta^{n+\alpha-1} (1-\theta)^{\sum x_i + \beta - n - 1} \end{aligned}$$

c'est une loi beta $\boxed{B\left(n+\alpha, \sum_{i=1}^n x_i + \beta - n\right)}$

L'estimateur MAP maximise la loi a posteriori et vérifie donc

$$\frac{\partial \ln P(\theta | x_1, \dots, x_n)}{\partial \theta} = 0 \Leftrightarrow \frac{\partial \ln P(\theta | x_1, \dots, x_n)}{\partial \theta} = 0$$

$$\Leftrightarrow \frac{\partial}{\partial \theta} \left[(n+\alpha-1) \ln \theta + (\sum x_i + \beta - n - 1) \ln(1-\theta) \right] = 0$$

$$\text{d'où} \quad \frac{n+\alpha-1}{\theta} - \frac{\sum x_i + \beta - n - 1}{1-\theta} = 0$$

En multipliant tout par $\theta(1-\theta)$, on obtient

(3)

$$(1-\theta)(n+\alpha-1) - \theta(\sum x_i + \beta - n - 1) = 0$$

Soit

$$n+\alpha-1 + \theta(-n-\alpha+1 - \sum x_i - \beta + n + 1) = 0$$

d'où

$$\theta = \frac{n+\alpha-1}{\sum x_i + \alpha + \beta - 2}$$

On en déduit

$$\hat{\theta}_{MAP} = \frac{n+\alpha-1}{\sum_{i=1}^n x_i + \alpha + \beta - 2}$$

On peut réécrire $\hat{\theta}_{MAP}$ sous la forme

$$\hat{\theta}_{MAP} = \frac{1 + \frac{\alpha-1}{n}}{\frac{1}{n} \sum_{i=1}^n x_i + \frac{\alpha+\beta-2}{n}} \sim \frac{1}{\bar{x}} = \hat{\theta}_{MV}$$

Comme d'habitude, $\hat{\theta}_{MAP}$ se comporte comme $\hat{\theta}_{MV}$ pour $n \rightarrow +\infty$.

Exercice 2: Remarque: la remarque ci-dessus est intéressante, même si elle n'était pas demandée à l'examen. Elle provient d'un rapport technique de Stanley L. Skone et John Van Ryzin intitulé "Some estimation problems related to a geometric distribution and a sum of two independent non-identically distributed random variables".

Le développement de Taylor de $\frac{1}{t}$ autour de $\frac{1}{t_0}$ s'écrit

$$\frac{1}{t} = \frac{1}{t_0} + \frac{t-t_0}{-t_0^2} + \frac{(t-t_0)^2}{t_0^3} - \frac{(t-t_0)^3}{t_0^4} + \dots$$

et il est valable au voisinage de t_0 .

Quand on l'applique à $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ et $t_0 = E(x_i) = \frac{1}{\theta}$, on obtient

$$\frac{1}{\bar{x}} = \theta - \theta^2 \left(\bar{x} - \frac{1}{\theta}\right) + \theta^3 \left(\bar{x} - \frac{1}{\theta}\right)^2 - \theta^4 \left(\bar{x} - \frac{1}{\theta}\right)^3 + \dots$$

D'où

$$E\left[\frac{1}{\bar{x}}\right] = \theta + 0 + \theta^3 E\left[\left(\bar{x} - \frac{1}{\theta}\right)^2\right] - \theta^4 E\left[\left(\bar{x} - \frac{1}{\theta}\right)^3\right] + \dots$$

$$\text{Mais } E\left[\left(\bar{x} - \frac{1}{\theta}\right)^2\right] = \text{Var } \bar{x} = \frac{\text{Var } x_i}{n} = \left[\frac{1-\theta}{\theta^2 n}\right]$$

$$\text{De même } E\left[\left(\bar{x} - \frac{1}{\theta}\right)^3\right] = E\left[\left(\frac{1}{n} \sum (x_i - \frac{1}{\theta})\right)^3\right] = \frac{1}{n^3} \sum_{i,j,k} E\left[\left(x_i - \frac{1}{\theta}\right)\left(x_j - \frac{1}{\theta}\right)\left(x_k - \frac{1}{\theta}\right)\right]$$

Tous les termes de la somme sont nuls sauf pour $i=j=k$. On obtient donc

$$E\left[\left(\bar{x} - \frac{1}{\theta}\right)^3\right] = \frac{1}{n^2} E\left[\left(x_i - \frac{1}{\theta}\right)^3\right] = \frac{\mu^3}{n^2}$$

d'où $E\left[\frac{1}{X}\right] = \theta + \frac{1-\theta}{n\theta^2} \times \theta^3 - \frac{\theta^4 \mu_3}{n^2} + \dots$

(4)

$$= \theta + \frac{\theta(1-\theta)}{n} - \frac{\mu_3 \theta^4}{n^2} + o\left(\frac{1}{n^2}\right)$$

Ceci permet de montrer que $\frac{1}{X}$ est un estimateur asymptotiquement sans biais de θ et que sa variance asymptotique est $\frac{\theta(1-\theta)}{n}$, qui est la borne de Cramer-Rao pour le paramètre θ

Exercice 2

1) Le test de Neyman Pearson s'écrit c'est-à-dire

$$\text{Rejet de } H_0 \text{ si } \frac{L(x_1, \dots, x_n; \theta_1)}{L(x_1, \dots, x_n; \theta_0)} > S_\alpha$$

Rejet de H_0 si $\frac{\theta_1^n (1-\theta_1)^{\sum x_i - n}}{\theta_0^n (1-\theta_0)^{\sum x_i - n}} > k_\alpha \Leftrightarrow \left(\frac{\sum x_i}{n}\right) \ln\left(\frac{1-\theta_1}{1-\theta_0}\right) > S_\alpha$

si $\theta_1 > \theta_0$, alors $1-\theta_1 < 1-\theta_0$ donc $\frac{1-\theta_1}{1-\theta_0} < 1$ donc $\ln\left(\frac{1-\theta_1}{1-\theta_0}\right) < 0$ donc

$$\boxed{\text{on rejette } H_0 \text{ si } \sum_{i=1}^n x_i < k_\alpha}$$

si $\theta_1 < \theta_0$, alors $\boxed{\text{on rejette } H_0 \text{ si } \sum_{i=1}^n x_i > k_\alpha}$

2) D'après le théorème de la limite centrale, pour n grand, on peut approcher la loi de $T_n = \sum_{i=1}^n x_i$ par une loi normale de moyenne $nE[x_i] = \frac{n}{\theta}$ et de variance $n\text{Var}[x_i] = \frac{n(1-\theta)}{\theta^2}$

donc $T_n \underset{n \text{ grand}}{\sim} N\left(\frac{n}{\theta}, \frac{n(1-\theta)}{\theta^2}\right)$

3) $\alpha = P[\text{Rejeter } H_0 | H_0 \text{ vraie}] = P\left[T_n < k_\alpha \mid T_n \sim N\left(\frac{n}{\theta_0}, \frac{n(1-\theta_0)}{\theta_0^2}\right)\right]$

$$\Rightarrow \alpha = F\left[\frac{k_\alpha - \frac{n}{\theta_0}}{\sqrt{\frac{n(1-\theta_0)}{\theta_0^2}}}\right]$$

On en déduit le seuil $k_\alpha = \frac{\sqrt{n(1-\theta_0)}}{\theta_0} F^{-1}(\alpha) + \frac{n}{\theta_0}$

$$4) \pi = P[\text{rejeter } H_0 \mid H_1 \text{ vraie}]$$

$$= P[T_n < k_\alpha \mid \theta = \theta_1]$$

$$= F \left[\frac{k_\alpha - \frac{n}{\theta_1}}{\sqrt{\frac{n(1-\theta_1)}{\theta_1^2}}} \right]$$

(5)

5) Conjecture


Il suffit de remplacer l'expression de k_α de 3) dans l'expression de π trouvée en 4) pour obtenir

$$\pi = F \left[\frac{\frac{n}{\theta_0} - \frac{n}{\theta_1}}{\sqrt{\frac{n(1-\theta_1)}{\theta_1^2}}} + \frac{\theta_1}{\theta_0} \sqrt{\frac{1-\theta_0}{1-\theta_1}} F^{-1}(\alpha) \right]$$

Soit

$$\pi = F \left[\frac{\sqrt{n} \left(\frac{\theta_1}{\theta_0} - 1 \right)}{\sqrt{1-\theta_1}} + \frac{\theta_1}{\theta_0} \sqrt{\frac{1-\theta_0}{1-\theta_1}} \right]$$

Plus n est grand, plus π est grande, ce qui donne les courbes suivantes



Exercice 3

$$1) \phi = \sum_{i=1}^6 \frac{(k_i - n p_i)^2}{n p_i} \quad \text{avec } n=60 \text{ et } p_i=10 \text{ soit } n p_i=10$$

$$\text{d'où } \phi = \frac{1}{10} \left[(10-10)^2 + (8-10)^2 + (10-10)^2 + (15-10)^2 + (5-10)^2 + (12-10)^2 \right]$$

$$= \frac{1}{10} [0 + 4 + 0 + 25 + 25 + 4] = \boxed{5.8}$$

$$2) \alpha = P[\phi > k_\alpha \mid \phi \sim \chi_5^2] = 1 - F_{\chi_5^2}(k_\alpha)$$

$$\text{d'où } k_\alpha = F_{\chi_5^2}^{-1}(1-\alpha)$$

Donc plus α est grand, plus on rejette H_0 donc plus k_α est faible

$\phi > k_\alpha$
rejet de H_0

k_α

EXERCICE 3

(6)

$$P(X_i = x_i) = \theta (1-\theta)^{x_i-1} \quad x_i = 1, 2, \dots$$

$$1) p_1 = \theta = 0.4$$

$$p_2 = \theta(1-\theta) = 0.4 \times 0.6 = 0.24$$

$$p_3 = \theta(1-\theta)^2 = 0.4 \times 0.36 = 0.144$$

$$p_4 = ~~0.096~~ 0.216$$

$$2) \phi_n = \frac{(5-8)^2}{8} + \frac{(6-4.8)^2}{4.8} + \frac{(4-2.88)^2}{2.88} + \frac{(5-4.32)^2}{4.32}$$

$$3) \phi_n \sim \chi_{k-1}^2 = 3$$

4) On rejette H_0 si $\phi_n > \kappa_\alpha$ avec $\alpha = P[\text{Rejete } H_0 | H_0 \text{ vraie}]$

Donc

$$\alpha = P[\phi_n > \kappa_\alpha | \phi_n \sim \chi_3^2] = 1 - F_{\chi_3^2}(\kappa_\alpha)$$

$$\Rightarrow \kappa_\alpha = F_{\chi_3^2}^{-1}(1-\alpha)$$

Bavens

Ex1 1) $\hat{\theta}_{MV} = \frac{1}{x} + \max$ global unique (1) + (1) = (2pts)

2) propri $\hat{a}_{MV} = \bar{x}$ et $\hat{\theta}_{MV}$ asympt (1)

$E(\hat{a}_{MV}) = a$ (1)

$Var(\hat{a}_{MV}) = \frac{a(a-1)}{n}$ (1)

3) BUR = $\frac{a(a-1)}{n}$ (2)

4) • $B(n+\alpha, \sum x_i + \beta - n)$ (1)

• $\hat{\theta}_{MAP} = \frac{n+\alpha-1}{\sum_{i=1}^n x_i + \alpha + \beta - 2}$ (1)

• $\hat{\theta}_{MAP} \sim \frac{1}{x} = \hat{\theta}_{MV}$ (1)

(2pts)

(3pts)

Ex2 1) $\theta_1 > \theta_0$ Rejet de H_0 si $\sum x_i < k_\alpha$
 $\theta_1 < \theta_0$ $\sum x_i > k_\alpha$ (2pts)

$E[x_i] = \frac{1}{\theta}$ donc si $\theta_1 > \theta_0$, on rejette H_0 si $\sum x_i < k_\alpha$

$n \times$ moyenne

c'est-à-dire si la moyenne est petite, ce qui est normal
 i.e θ grand (1pt)

2) $T_n \sim N\left(\frac{n}{\theta}, \frac{n(1-\theta)}{\theta^2}\right)$ (1pt)

3) $k_\alpha = \frac{1}{\theta_0} \sqrt{n(1-\theta_0)} F^{-1}(\alpha) + \frac{n}{\theta_0}$ (1pt)

4) $\pi = F\left[\frac{k_\alpha - \frac{n}{\theta_1}}{\frac{1}{\theta_1} \sqrt{n(1-\theta_1)}}\right]$ (1pt)

5) $\pi = F\left[\frac{\sqrt{n} \left(\frac{\theta_1}{\theta_0} - 1\right)}{\sqrt{1-\theta_1}} + \frac{\theta_1}{\theta_0} \sqrt{\frac{1-\theta_0}{1-\theta_1}}\right]$ (2pts)



(1pt)

Ex3 1) $\phi = S.R$ (1)

2) $k_\alpha = F_{\chi^2}^{-1}(1-\alpha)$ (1)

3) $\alpha \nearrow k_\alpha \searrow$ (1)

(3pts)