

Semaine 2: Estimateur du maximum de vraisemblance Éléments de corrigé

Objectifs de la séance:

- Distinguer densité et vraisemblance
- Calculer la borne de Cramér-Rao, déterminer si un estimateur est efficace
- Calculer un EMV et déterminer sa loi asymptotique
- Révision: construction d'un intervalle de confiance

La séance de TD comprend les exercices 1 à 3. Les autres exercices permettent de s'entraîner et d'approfondir.

1 Vraisemblance

Comparer le domaine de définition de la densité d'un n -échantillon iid d'une loi de Bernoulli $\mathcal{B}(1, \theta)$ et celui de sa vraisemblance; donner l'allure de la vraisemblance; déterminer l'estimateur du maximum de vraisemblance; calculer l'information de Fisher et la borne de Cramér-Rao.

Correction. La densité de l'échantillon est une fonction de $\{0, 1\}^{\otimes n}$ dans $[0, 1]$, tandis que la vraisemblance est une fonction de $[0, 1]$ dans $[0, 1]$. Les observations étant indépendantes, la vraisemblance est le produit des vraisemblances individuelles:

$$L(\theta; x) = \prod_i f(x_i; \theta) = \theta^s (1 - \theta)^{n-s} = \theta^s (1 - \theta)^{n-s}$$

On voit que la vraisemblance ne dépend plus que de $S = \sum_i X_i$ (S est une statistique exhaustive, pour les curieux, voir poly section 2.3). La forme de la vraisemblance dépend de la valeur de S qui prend ses valeurs dans $s = 0, \dots, n$. La vraisemblance est représentée pour quelques valeurs de s figure ??.

La log-vraisemblance s'écrit $\ell_\theta(S) = S \log(\theta) + (n - S)/(1 - \theta)$, de dérivée par rapport à θ : $\dot{\ell}_\theta(S) = S/\theta - (n - S)/(1 - \theta)$, d'où $\hat{\theta} = \bar{X}$. On vérifie que la dérivée seconde est négative

$$\ddot{\ell}_\theta(X) = -\frac{S}{\theta^2} - \frac{n - S}{(1 - \theta)^2} < 0$$

$\hat{\theta} = \bar{X}$ est l'EMV de θ . L'information de Fisher vaut $I_n(\theta) = -\mathbb{E}(\ddot{\ell}_\theta(S)) = n/(\theta - \theta^2) = 1/\text{var}(\hat{\theta})$. $\hat{\theta}$ est sans biais et atteint la BCR, il est donc efficace.

Reprendre ces questions pour un n -échantillon de loi Uniforme $\mathcal{U}_{[0; \theta]}$ ($\theta > 0$), puis de loi Gaussienne $\mathcal{N}(\mu, \sigma^2)$.

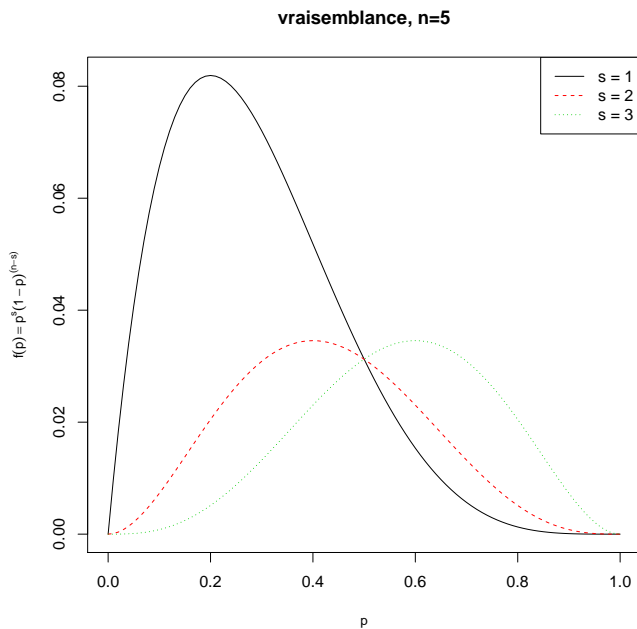


Figure 1: Cas Bernoulli: fonction de vraisemblance représentée pour trois valeurs de la statistique exhaustive

Correction. Loi uniforme ($\theta > 0$): La densité de l'échantillon par rapport à la mesure de Lebesgue est une fonction de \mathbb{R}^n dans $\{0, 1/\theta^n\}$, tandis que la vraisemblance est une fonction de θ , de \mathbb{R}^{+*} dans \mathbb{R}^+ . Le support de la loi dépend du paramètre inconnu, le modèle n'est pas régulier. La densité d'un n -échantillon peut s'écrire

$$f(x_1, \dots, x_n; \theta) = \theta^{-n} \mathbb{I}_{0 \leq \min_i x_i \leq \max_i x_i \leq \theta} = \theta^{-n} \mathbb{I}_{0 \leq \max_i x_i \leq \theta}.$$

$\theta \mapsto L(\theta, x)$ est une fonction nulle pour $\theta < \max_i x_i$. Elle vaut $1/\theta^n$ (et donc décroissante) pour $\theta > \max_i x_i$. Ainsi, son maximum est en $\max_i x_i$, d'où l'EMV est $\max_i X_i$. Le modèle n'est pas régulier, on ne peut définir de BCR.

Loi gaussienne: La densité de l'échantillon est une fonction de \mathbb{R}^n dans \mathbb{R}^{+*} , tandis que la vraisemblance est une fonction de $\mathbb{R} \times \mathbb{R}^{+*}$ dans \mathbb{R}^{+*} . On écrit la vraisemblance pour $\theta = (\mu, \sigma^2)$

$$L(\theta; x) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left(-\frac{\sum_i (x_i - \mu)^2}{2\sigma^2}\right) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left(-\frac{\sum_i x_i^2 - 2\mu \sum_i x_i + n\mu^2}{2\sigma^2}\right)$$

La fonction de vraisemblance est une gaussienne (à σ fixé) et la forme d'une inverse Gamma à μ fixé. La dérivée de la log-vraisemblance est le vecteur du score

$$\left(\frac{\sum_i x_i - n\mu}{\sigma^2} ; -\frac{n}{2\sigma^2} + \frac{\sum_i (x_i - \mu)^2}{2\sigma^4} \right)$$

qui possède un unique point critique $\hat{\theta} = (\bar{x}, \sum_i (x_i - \bar{x})^2/n)$. La hessienne au point critique est la matrice diagonale de coefficients diagonaux $(-n/\hat{\sigma}^4; -n/(2\hat{\sigma}^4))$ qui est bien définie négative; d'où l'EMV $\hat{\theta} = (\bar{X}, \sum_i (X_i - \bar{X})^2/n)$.

2 Loi exponentielle

Soit un n -échantillon de loi exponentielle dépendant du paramètre $\mu > 0$ et définie pour $x \geq 0$ par $f(x) = \frac{1}{\mu} \exp(-\frac{x}{\mu})$. On rappelle que $\mathbb{E}(X) = \mu$ et $\text{var}(X) = \mu^2$.

1. Calculer l'estimateur du maximum de vraisemblance $\hat{\mu}$. Celui-ci est-t-il sans biais? efficace ? consistant ? uniformément de variance minimum parmi les estimateurs sans biais (UVMB)?

Correction. Soit

$$L_n(\mu) = -n \log \mu - \sum_i X_i/\mu$$

la log-vraisemblance. L'EMV annule l'équation de score $dL_n/d\mu = 0$, soit $\hat{\mu} = \bar{X}$ et on vérifie que la dérivée seconde est négative autour du maximum. L'information de Fisher vaut $I_n(\mu) = n/\mu^2$. L'estimateur est sans biais ($\mathbb{E}(\hat{\mu}) = \mu$), sa variance $\text{var}(\hat{\mu}) = \mu^2/n$ atteint la borne de Cramer-Rao $I_n(\mu)^{-1}$: il est donc efficace et donc en particulier UVMB. Il est consistant car sans biais et de variance tendant vers 0; ou LGN.

2. Déterminer la loi de $\hat{\mu}$ à distance finie, puis sa loi asymptotique. Déterminer un intervalle de confiance bilatère (probabilité symétrique) de μ de niveau $1 - \alpha$.

Rappel: la somme de n variables indépendantes de loi exponentielle d'espérance 1 suit une loi Gamma $Ga(n, 1)$.

Correction. $X_i/\mu \sim Ga(n, 1)$. L'échantillon étant iid, $T_n = \sum_i X_i/\mu \sim \mathcal{G}(n, 1)$ qui est une statistique pivotale (sa loi ne dépend pas de μ). On a l'intervalle de fluctuation pour T de probabilité $1 - \alpha$

$$\mathbb{P}_{\mu_0} \left(g_n(\alpha/2) \leq T_n \leq g_n(1 - \alpha/2) \right) = 1 - \alpha$$

avec $g_n(\alpha/2)$ et $g_n(1 - \alpha/2)$ les quantiles d'ordre $\alpha/2$ et $1 - \alpha/2$ d'une loi $\mathcal{G}(n, 1)$. D'où l'IC de niveau $1 - \alpha$

$$IC = \left[\frac{\sum_i X_i}{g_n(1 - \alpha/2)}; \frac{\sum_i X_i}{g_n(\alpha/2)} \right] \text{ avec } \mathbb{P}(IC \ni \mu) = 1 - \alpha$$

D'après le TLC (moyenne empirique d'un n -échantillon iid de variance finie), $T_n^* = \sqrt{n}(\bar{X}/\mu - 1) \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1)$. D'où

$$\mathbb{P}_{\mu_0} \left(|T_n^*| < q_{1-\alpha/2}^* \right) \simeq 1 - \alpha$$

où $q_{1-\alpha/2}^*$ est le quantile d'ordre $1 - \alpha/2$ de la loi gaussienne centrée réduite. On en déduit l'IC de niveau asymptotique $1 - \alpha$,

$$IC_{asym} = \left[\frac{\bar{X}}{1 + q_{1-\alpha/2}^*/\sqrt{n}}; \frac{\bar{X}}{1 - q_{1-\alpha/2}^*/\sqrt{n}} \right] \text{ avec } \mathbb{P}(IC \ni \mu) \simeq 1 - \alpha$$

A distance finie, le niveau vaut approximativement $1 - \alpha$.

3. On estime maintenant $\lambda = 1/\mu$.

(a) Quelle est la borne de Cramer-Rao pour un estimateur sans biais de λ ?

Correction. Soit $\lambda = h(\mu) = 1/\mu$. La borne de Cramér-Rao pour λ est

$$BCR(\lambda) = [\dot{h}(\mu)]^2 [I_n(\mu)]^{-1} = \lambda^2/n.$$

où $\dot{h}(\mu)$ est la dérivée de h par rapport à μ .

(b) Montrer que l'estimateur $\hat{\lambda} = (n-1)/\sum X_i$ est non biaisé pour l'estimation de λ . Est-il efficace? Asymptotiquement efficace? Déterminer sa loi asymptotique.

Correction. On a $\lambda \sum_i X_i \sim \mathcal{Ga}(n, 1)$. Et, en utilisant le rappel (en fin d'énoncé de TD) de la définition de la densité f_Γ de la loi Gamma,

$$\begin{aligned} \mathbb{E}\left(\frac{1}{\lambda \sum_i X_i}\right) &= \int \frac{1}{s} f_\Gamma(s) ds = \int \frac{1}{\Gamma(n)} s^{n-2} \exp(-s) ds \\ &= \frac{1}{n-1} \int \frac{1}{\Gamma(n-1)} s^{n-2} \exp(-s) ds = \frac{1}{n-1} \end{aligned}$$

d'où $\mathbb{E}((n-1)/\sum_i X_i) = \lambda$ et $\hat{\lambda}$ est non biaisé. Sa variance vaut $\lambda^2/(n-2) > \lambda^2/n = BCR(\lambda)$, il n'est donc pas efficace, mais asymptotiquement efficace. On peut retrouver le résultat asymptotique en utilisant la delta-méthode

$$\sqrt{n}(h(\hat{\mu}) - h(\mu)) \xrightarrow{\mathcal{L}} \mathcal{N}\left(0, [\dot{h}(\mu)]^2 / I_1(\mu)\right)$$

3 Loi de Bernoulli

Soit un n -échantillon de loi de Bernoulli $\mathcal{B}(p)$. Déterminer la borne de Cramer-Rao pour un estimateur sans biais de la cote $p/(1-p)$. Proposer un estimateur asymptotiquement efficace.

Correction. On a vu à l'exercice 1 que l'information de Fisher de l'échantillon de Bernoulli vaut $I_n(p) = n/(p-p^2)$. Donc la borne de Cramér-Rao pour un estimateur sans biais de $h(p) = p/(1-p)$ vaut

$$BCR(h(p)) = [\dot{h}(p)]^2 [I_n(p)]^{-1} = \frac{p}{n(1-p)^3}$$

où $\dot{h}(p) = 1/(1-p)^2$ est la dérivée de h par rapport à p . L'estimateur du maximum de vraisemblance de p est asymptotiquement gaussien, asymptotiquement efficace et de variance asymptotique la BCR. On utilise la méthode delta avec la fonction $h(p)$ et on trouve que $h(\bar{X}) = \bar{X}/(1-\bar{X})$ est un estimateur asymptotiquement gaussien et efficace:

$$\sqrt{n}(h(\hat{p}) - h(p)) \xrightarrow{\mathcal{L}} \mathcal{N}(0, p/(1-p)^3)$$

4 Loi de Weibull

La durée de vie d'un matériel peut être modélisée par une variable aléatoire X qui suit une loi de Weibull $\mathcal{W}(\lambda, 1/2)$ de densité

$$f(x, \lambda) = \frac{1}{2\lambda\sqrt{x}} \exp\left(-\frac{\sqrt{x}}{\lambda}\right) \mathbb{I}_{x>0}$$

Son espérance vaut $\mathbb{E}(X) = \lambda\Gamma(3) = 2\lambda$ et sa variance $\text{var}(X) = \lambda^2\Gamma(5) - \mathbb{E}(X)^2$.

1. La loi de Weibull $\mathcal{W}(\lambda, 1/2)$ appartient-elle à la famille exponentielle? Proposer une statistique exhaustive.

Correction.

$$\log(f(x, \lambda)) = -\frac{\sqrt{x}}{\lambda} - \log(2\lambda) - \frac{1}{2}\log(x) = \alpha(\lambda)a(x) + \beta(\lambda) + c(x)$$

On reconnaît la forme d'une loi de la famille exponentielle avec $\alpha(\lambda) = -\frac{1}{\lambda}$, $a(x) = \sqrt{x}$, $\beta(\lambda) = -\log(2\lambda)$, $c(x) = \frac{1}{2}\log(x)$.

Par le principe de factorisation, $\sum_i a(X_i) = \sum_i \sqrt{X_i}$ est une statistique exhaustive.

2. Déterminer l'estimateur du maximum de vraisemblance $\hat{\lambda}$ de λ à partir d'un n -échantillon i.i.d. (X_1, \dots, X_n) de loi $\mathcal{W}(\lambda, 1/2)$.

Correction. On dérive la logvraisemblance

$$\frac{\partial}{\partial \lambda} \log f(x, \lambda) = \sum_i \frac{\sqrt{X_i}}{\lambda^2} - \frac{n}{\lambda} = 0$$

d'où l'EMV $\hat{\lambda} = \sum_i \sqrt{X_i}/n$. Le hessien vaut

$$H_n = \frac{\partial^2}{\partial \lambda^2} \log f(x, \lambda) = -2 \frac{\sum_i \sqrt{X_i}}{\lambda^3} + \frac{n}{\lambda^2}$$

néglatif autour de l'EMV, c'est un maximum. L'étude de la log-vraisemblance indique d'ailleurs que c'est l'unique maximum.

3. Déterminer la loi de $\hat{\lambda}$. Aide: montrer que \sqrt{X} suit une loi exponentielle d'espérance à déterminer, et en déduire que si (X_1, \dots, X_n) est un n -échantillon i.i.d. de loi $\mathcal{W}(\lambda, 1/2)$, alors $2 \sum_i \sqrt{X_i}/\lambda \sim \chi^2(2n)$.

Correction. Pour toute fonction φ continue et bornée, on a

$$\mathbb{E}(\varphi(\sqrt{X})) = \int_0^\infty \varphi(\sqrt{x}) \frac{1}{2\lambda\sqrt{x}} \exp\left(-\frac{\sqrt{x}}{\lambda}\right) dx = \int_0^\infty \varphi(y) \frac{1}{\lambda} \exp\left(-\frac{y}{\lambda}\right) dy$$

où on reconnaît la densité d'une loi exponentielle d'espérance λ . On en déduit $\sqrt{X}/\lambda \sim \mathcal{E}(1)$ (même principe). Soit $S_n = \sum_i Z_i$ où $Z_i \sim \mathcal{E}(1)$.

$$\mathbb{E}(\varphi(2S_n)) = \int_0^\infty \varphi(2s) \frac{s^{n-1}}{\Gamma(n)} \exp\left(-\frac{s}{\lambda}\right) ds = \int_0^\infty 2^{-n} n \frac{y^{n-1}}{\Gamma(n)} \exp\left(-\frac{y}{2}\right) dy$$

où on reconnaît la densité d'une loi du $\chi^2(2n)$. Donc $\frac{2n}{\lambda} \hat{\lambda} \sim \chi^2(2n)$

4. Calculer l'information de Fisher. $\hat{\lambda}$ est-il efficace?

Correction. $\hat{\lambda}$ est non biaisé, de variance $\text{var}(\hat{\lambda}) = \text{var}(\sqrt{X_1})/n = \lambda^2/n$. L'information de Fisher $I_n = \mathbb{E}(-H_n) = n/\lambda^2$. La variance atteint bien l'inverse de l'information de Fisher.

Ce qui est cohérent avec le fait que la seule fonction de λ (à une transformation affine près) qu'on sait estimer efficacement dans le modèle exponentiel est une fonction affine de $\mathbb{E}(\sum_i \sqrt{X_i})/n = \lambda$.

5 Loi uniforme

Soit X_1, \dots, X_n un n -échantillon de loi uniforme $\mathcal{U}_{[0;\theta]}$, où $\theta > 0$ est le paramètre inconnu.

1. Déterminer les performances de l'estimateur des moments.

Correction. On a : $\mathbb{E}(X_1) = \theta/2$. D'où $\hat{\theta}_m = \bar{X}/2$, estimateur sans biais. Par la LGN, $\hat{\theta}_m$ est (fortement) consistant et par le TLC il est asymptotiquement gaussien: $\sqrt{n}(\hat{\theta}_m - \theta) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \text{var}(X_1) = \theta^2/12)$.

2. Montrer que l'estimateur du maximum de vraisemblance est $T_n = \max_i X_i$, de densité

$$h_\theta(t) = \frac{n}{\theta^n} t^{n-1} \mathbb{I}_{[0;\theta]}(t).$$

Correction. $\theta \mapsto L(\theta, x)$ est une fonction nulle pour $\theta < \max_i x_i$. Elle vaut $1/\theta^n$ (et donc décroissante) pour $\theta > \max_i x_i$. Ainsi, son maximum est en $\max_i x_i$, d'où l'EMV est $T_n = \max_i X_i$. En utilisant l'indépendance des observations X_i de loi F :

$$\mathbb{P}(T_n \leq x) = \mathbb{P}(\cap_{i=1}^n (X_i \leq x)) = \prod_{i=1}^n \mathbb{P}(X_i \leq x) = F^n(x).$$

La densité de T_n est donc, par dérivation en x

$$h_\theta(x) = nF^{n-1}(x)f(x) = \frac{n}{\theta^n} x^{n-1} \mathbb{I}_{[0;\theta]}(t)$$

3. Montrer que T_n est biaisé. En déduire un estimateur non biaisé \tilde{T}_n . \tilde{T}_n est-il efficace?

Correction. D'où

$$\mathbb{E}(T_n) = n\theta^{-n} \int_0^\theta x^n dx = \frac{n}{n+1}\theta; \quad \text{var}(T_n) = \frac{n\theta^2}{(n+1)^2(n+2)}$$

T_n est donc biaisé, de biais $-\theta/n$. L'estimateur $T_n^* = (n+1)T_n/n$ est sans biais. Mais on ne peut calculer de borne de Cramer-Rao (ni parler d'efficacité) puisque le modèle n'est pas régulier. Le calcul montre que son risque est inférieur à celui de T_n . Mais il n'est pas admissible parce que $\tilde{T}_n = (n+2)T_n/(n+1)$, bien que légèrement biaisé, est de risque inférieur.

4. Montrer que T_n est consistant, puis la convergence suivante: $n(1 - T_n/\theta) \xrightarrow{\mathcal{L}} \mathcal{E}(1)$.

Correction. *Consistance:* soit F_T la fonction de répartition de T_n . pour tout $\varepsilon > 0$, on a

$$\mathbb{P}\left(|T_n - \theta| > \varepsilon\right) = \mathbb{P}\left(\max_i X_i < \theta - \varepsilon\right) = F_T(\theta - \varepsilon) = \left(\frac{\theta - \varepsilon}{\theta}\right)^n$$

expression qui tend vers 0 quand $n \rightarrow \infty$

La convergence en loi se démontre par un théorème de convergence dominée: pour toute fonction g continue et bornée, on a

$$\begin{aligned} \mathbb{E}\left(g(n(1 - T_n/\theta))\right) &= \int_0^\theta g(n(\theta - t)) \frac{n}{\theta^n} t^{n-1} dt \\ &= \int_{\mathbb{R}^+} g(u) f_n(u) du \end{aligned}$$

avec $f_n(u) = \left(1 - \frac{u}{\theta}\right)^{n-1} \mathbb{1}_{[0;n]}(u)$. Or, $f_n(u)$ tend ponctuellement vers $\exp(-u)$ pour tout u et comme $\log f_n(u) \leq -u/2$ dès que $n \geq 2$, on a $|g(u)f_n(u)| \leq |g|_\infty \exp(-u/2)$ d'intégrale finie. On en déduit que

$$\mathbb{E}\left(g(n(1 - T_n/\theta))\right) \rightarrow \int g(u) e^{-u} \mathbb{1}_{\mathbb{R}^+}(u) du$$

La loi limite de $n(1 - T_n/\theta)$ est donc une loi exponentielle d'espérance 1. La vitesse est en n (alors que celle de l'estimateur de moments est en \sqrt{n} , infiniment plus lente).

Note: La densité d'une loi du Khi-deux $\chi^2(k)$ à k degrés de liberté est définie pour $x \geq 0$ par $f_\chi(x) = \frac{2^{-k/2}}{\Gamma(k/2)} x^{k/2-1} \exp(-x/2)$ La densité d'une loi Gamma $\mathcal{G}(n, \theta)$ est définie pour $x \geq 0$ par $f_\Gamma(x) = \frac{\theta^{-n}}{\Gamma(n)} x^{n-1} \exp(-x/\theta)$