

Chapitre Final + 1

L'examen: 5 mai 14h - 16h

Zoom ID: 858 - 2287 - 6565

Mot de passe: ens

I. Information de Fisher.

1) Lien avec ENV

Déf L'information de Fisher d'une variable aléatoire X_1 de loi p_θ , $\theta \in \Theta$ est définie par

$$I(\theta) = E_\theta [\ell'_{X_1}(\theta)^2]$$

↑ log-vraisemblance d'un 1-échantillon x .

Dans ce chapitre, on choisit de prouver les résultats avec les VA à densité.

Prop $E_\theta [\ell''_{X_1}(\theta)] = E_\theta \left[\frac{\partial^2}{\partial \theta^2} \ln f_\theta(x_1) \right] = -I(\theta)$

Dém: On note f_θ la densité de X_1 .

$$l'_{X_1}(\theta) = \frac{\partial}{\partial \theta} \ln f_\theta(x_1) = \frac{\partial_\theta f_\theta(x_1)}{f_\theta(x_1)}$$

$$l''_{X_1}(\theta) = \frac{\partial^2 f_\theta(x_1)}{f_\theta(x_1)} - \frac{(\partial_\theta f_\theta(x_1))^2}{f_\theta(x_1)^2}$$

$\overbrace{l'_{X_1}(\theta)}^2$

$$\begin{aligned} \text{On a } \bar{E}_\theta[l''_{X_1}(\theta)] &= \bar{E}_\theta\left[\frac{\partial^2 f_\theta(x_1)}{f_\theta(x_1)}\right] - I(\theta) \\ &= \int \frac{\partial^2 f_\theta(x)}{f_\theta(x)} f_\theta(x) dx - I(\theta) \\ &= 0 ? \end{aligned}$$

En effet, $\int f_\theta(x) dx = 1$, en dérivant par rapport à θ deux fois:

$$\int \partial_\theta^2 f_\theta(x) dx = 0$$

Th (Normalité asymptotique de EMV)

$X = (X_1, \dots, X_n)$ un n -échantillon de loi P_θ , $\theta \in \Theta$. $\hat{\theta}_n$ EMV de θ ,

$I(\theta)$ l'information de Fisher de X . Sans certaines hypothèses de régularité,

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow[n \rightarrow \infty]{\text{Loi}} N(0, \frac{1}{I(\theta)})$$

Dém: L'EMV $\hat{\theta}_n$ satisfait $l_X'(\hat{\theta}_n) = 0$

Par Taylor,

$$0 = l_X'(\hat{\theta}_n) \simeq l_X'(\theta) + (\hat{\theta}_n - \theta) l_X''(\theta)$$

$$\text{D'où } \bar{l}_n(\hat{\theta}_n - \theta) \simeq - \frac{\bar{l}_n l_X'(\theta)}{l_X''(\theta)}$$

$$l_X'(\theta) = \sum_{i=1}^n l_{X_i}'(\theta) \quad \text{avec} \quad l_{X_i}'(\theta) = \frac{\partial_\theta f_\theta(x_i)}{f_\theta(x_i)}$$

$$\star E_\theta[l_{X_i}'(\theta)] = \int \partial_\theta f_\theta(x) dx = 0$$

$$\star E_\theta[l_{X_i}'(\theta)^2] = I(\theta) \quad \text{TCL}$$

$$\text{Ainsi } \frac{\bar{l}_n l_X'(\theta)}{n} = \bar{l}_n \left(\frac{\sum_{i=1}^n l_{X_i}'(\theta)}{n} - 0 \right) \xrightarrow[n \rightarrow \infty]{\text{Loi}} N(0, I(\theta))$$

$$\Omega_n - \frac{\ell_{X_1}''(\theta)}{n} = - \frac{\sum_{i=1}^n \ell_{X_i}''(\theta)}{n} \xrightarrow[n \rightarrow \infty]{\text{P.S.}} - \mathbb{E}_\theta [\ell_{X_1}''(\theta)] = \mathcal{I}(\theta)$$

LGN

Par le lemme de Slutsky,

$$\sqrt{n}(\hat{\theta}_n - \theta) \underset{n \rightarrow \infty}{\sim} \frac{\frac{\sqrt{n} \ell_{X_1}'(\theta)}{-\ell_{X_1}''(\theta)}}{\frac{\mathcal{I}(\theta)}{n}} \sim N(0, \frac{1}{\mathcal{I}(\theta)})$$

Ex: Soit (X_1, \dots, X_n) un n -échantillon de $\text{lg} \cdot \beta(\theta)$, $0 < \theta < 1$.

$$\ell_{X_1}(\theta) = X_1 \ln \theta + (1-X_1) \ln(1-\theta) \rightarrow \ln f_\theta(x_1) \text{ avec } f_\theta(x) = \begin{cases} \theta & x=1 \\ 1-\theta & x=0 \end{cases}$$

$$\ell_{X_1}''(\theta) = -\frac{X_1}{\theta^2} - \frac{1-X_1}{(1-\theta)^2}$$

$$\mathcal{I}(\theta) = -\mathbb{E}_\theta [\ell_{X_1}''(\theta)] = \frac{1}{\theta} + \frac{1}{1-\theta} = \frac{1}{\theta(1-\theta)}$$

$$\text{EMV: } \hat{\theta}_n = \bar{X}_n$$

Par le th précédent, $\sqrt{n}(\bar{X}_n - \theta) \xrightarrow[n \rightarrow \infty]{\text{LGN}} N(0, \frac{\theta(1-\theta)}{\mathcal{I}(\theta)})$

Ex2: (X_1, \dots, X_n) un n -échantillon de loi $\overset{\text{densité}}{\underset{x>0}{\sim}} \frac{1}{I(\alpha)} x^{\alpha-1} e^{-x}$

$$l_{X_1}(\alpha) = -[\ln I(\alpha) + (\alpha-1) \ln X_1 - X_1]$$

$$l_{X_1}'(\alpha) = -\psi'(\alpha) \quad \text{où } \psi(\alpha) = \frac{I'(\alpha)}{I(\alpha)}$$

$$\text{D'où } Z(\alpha) = -\bar{E}_\alpha[l_{X_1}''(\alpha)] = \psi'(\alpha) \quad (>0)$$

Ensuite on cherche EMV:

$$l_X(\alpha) = n \left(-\ln I(\alpha) + (\alpha-1) \overline{\ln X_n} - \bar{X}_n \right)$$

$$\frac{1}{n} l_X'(\alpha) = -\psi'(\alpha) + \overline{\ln X_n} = 0$$

$$\text{Donc l'EMV } \hat{\alpha}_n = \psi^{-1}(\overline{\ln X_n}).$$

$$\text{Par le th précédent, } \sqrt{n} (\hat{\alpha}_n - \alpha) \xrightarrow[n \rightarrow \infty]{\mathcal{D}_{\alpha}} \mathcal{N}(0, \frac{1}{\psi'(\alpha)})$$

2) borne de Cramér-Rao

Prop (Inégalité de Cauchy) Soient X et Y deux VA réelles,

alors $\mathbb{E}[XY]^2 \leq \mathbb{E}[X^2]\mathbb{E}[Y^2]$

avec égalité $\Leftrightarrow X = cY$ ps.
cste

Th (Borne de Cramér-Rao) (X_1, \dots, X_n) un n -échantillon de loi P_θ , $\theta \in \Theta$.

$\hat{\theta}_n$ un estimateur sans biais de θ . Alors

$$\text{Var}_\theta(\hat{\theta}_n) \geq \frac{1}{n I(\theta)}$$

Dém: $\hat{\theta}_n$ est une fonction de X_1, \dots, X_n , on écrit

$$\hat{\theta}_n = h(X_1, \dots, X_n)$$

$\hat{\theta}_n$ est sans biais

$$\exp(h(x_1, \dots, x_n)(\theta))$$

$$\Rightarrow \int_{\mathbb{R}^n} h(x_1, \dots, x_n) f_\theta(x_1) \dots f_\theta(x_n) dx_1 \dots dx_n = \theta$$

En dérivant / θ :

$$\underbrace{\int_{\mathbb{R}^n} h(x_1, \dots, x_n) l'_{(x_1, \dots, x_n)}(\theta) f_\theta(x_1) \cdots f_\theta(x_n) dx_1 \cdots dx_n}_{\bar{E}_\theta[\hat{\theta}_n l'_X(\theta)]] = 1$$

De la même façon, on a

$$\bar{E}_\theta[l'_X(\theta)] = n \bar{E}_\theta[l'_{X_1}(\theta)] = n \int_{\mathbb{R}} \partial_\theta f_\theta(x) dx = 0$$

Par conséquent, $\bar{E}_\theta[(\hat{\theta}_n - \theta) l'_X(\theta)] = 1$.

On applique l'inégalité de Cauchy :

$$1 = \bar{E}_\theta[(\hat{\theta}_n - \theta) l'_X(\theta)]^2 \leq \text{Var}_\theta(\hat{\theta}_n) \bar{E}_\theta[l'_X(\theta)^2]$$

$$\text{et } \bar{E}_\theta[l'_X(\theta)^2] = n \bar{E}_\theta[l'_{X_1}(\theta)^2] = n I(\theta)$$

$$\text{d'où } \text{Var}_\theta(\hat{\theta}_n) \geq \frac{1}{n I(\theta)}$$

Rq: L'égalité est atteinte si: $\hat{\theta}_n = \theta + \underbrace{(\ell_X'(\theta))^{-1}}_{\text{une fonction de } \theta} \ell_X(\theta)$

Rqz: L'EMV $\hat{\theta}_n$. On a

$$\hat{\theta}_n - \theta \xrightarrow[n \rightarrow \infty]{\text{Lévy}} N(0, \frac{1}{I(\theta)})$$

$$\forall f \in E_b, [E(f(x_n))] \xrightarrow[n \rightarrow \infty]{} [E(f(x))]$$

Une conséquence est que

$$n \bar{E}_{\theta} [(\hat{\theta}_n - \theta)^2] \xrightarrow[n \rightarrow \infty]{} \frac{1}{I(\theta)}$$

Si $\hat{\theta}_n$ est sans biais, ceci implique que

$$\text{Var}_{\theta} (\hat{\theta}_n) \underset{n \rightarrow \infty}{\approx} \frac{1}{n I(\theta)}$$

La borne de Cramér-Rao est atteinte asymptotiquement! Autrement dit, un EMV sans biais est asymptotiquement optimal (au sens de moindre variance) parmi tous les estimateurs sans biais.

3) Tests du rapport de vraisemblance asymptotique.

Rappel : $H_0: \theta \in \Theta_0$ contre $H_1: \theta \notin \Theta_0$

Rapport de vraisemblance :

$$T(X) = \frac{\sup_{\theta \in \Theta_1} V_X(\theta)}{\sup_{\theta \in \Theta_0} V_X(\theta)}$$

Le test s'écrit $\{ T(X) > t_\alpha \}$

Th (X_1, \dots, X_n) un n -échantillon de loi P_θ , $\theta \in \Theta \subseteq \mathbb{R}^d$. On considère

$H_0: \theta = \theta_0$ contre $H_1: \theta \neq \theta_0$. Sous certaines hypothèses de régularité (pour la consistance et normalité asymptotique de l'EMV),

$$2 \ln T(X) \xrightarrow[n \rightarrow \infty]{\text{d}} \chi^2(d)$$

Idée : l'ENV $\hat{\theta}_n$. On illustre $d=1$.

$$2 \ln T(X) = 2 \ell_X(\hat{\theta}_n) - 2 \ell_X(\theta_0)$$

Par Taylor,

$$\begin{aligned} \ell_X(\theta_0) &\simeq \ell_X(\hat{\theta}_n) + \underbrace{\ell'_X(\hat{\theta}_n)(\theta_0 - \hat{\theta}_n)}_0 + \frac{1}{2} \underbrace{\ell''_X(\hat{\theta}_n)}_{\simeq \ell''_X(\theta_0)} (\theta_0 - \hat{\theta}_n)^2 \\ \text{Donc } 2 \ln T(X) &\simeq n I(\theta_0) (\theta_0 - \hat{\theta}_n)^2 \\ &= \sum_{i=1}^n \ell''_{X_i}(\theta_0) \\ &\simeq -n I(\theta_0) \end{aligned}$$

Par la normalité asymptotique de $\hat{\theta}_n$:

$$\sqrt{n} \overline{\ell''(X_i)} (\hat{\theta}_n - \theta_0) \xrightarrow[n \rightarrow \infty]{\text{L'H}} N(0, 1)$$

$$\text{Ainsi } 2 \ln T(X) \xrightarrow[n \rightarrow \infty]{\text{L'H}} \chi^2(1)$$

Cov: Un test du rapport de vraisemblance de

$H_0: " \theta = \theta_0 "$ contre $H_1: " \theta \neq \theta_0 "$ de niveau α est

$$\text{II } 2 \ln T(X) > C_{1-\alpha}^{(\alpha)}$$

Ex: X_1, \dots, X_n i.i.d. $\sim N(\theta, 1)$

$H_0: "θ=0"$ contre $H_1: "θ ≠ 0"$

L'ENV est $\hat{\theta}_n = \bar{X}_n$.

$$\begin{aligned}2 \ln T(\kappa) &= 2 \ell_X(\hat{\theta}_n) - 2 \ell_X(0) \\&= - \sum_{i=1}^n (x_i - \bar{X}_n)^2 + \sum_{i=1}^n x_i^2 \\&\stackrel{\text{blue arrow}}{=} (\sum_n \bar{X}_n)^2 \sim \chi^2(1) \\&\quad \bar{X}_n \sim N(0, 1)\end{aligned}$$

II. Estimation Bayésienne.

1) Loi a priori et a posteriori

Dans l'approche Bayésienne, on dispose d'une information a priori sur le paramètre inconnu θ . Cette information prend la forme d'une loi sur l'espace des paramètres

④, notée p , qui s'appelle la loi à priori. Le paramètre θ devient une variable aléatoire de densité $p(\theta)$.

Déf: La loi jointe des observations $X = (X_1, \dots, X_n)$ conditionnelle à θ

$$\text{est notée } p(x|\theta) = \begin{cases} f(x_1, \dots, x_n|\theta) & \text{continu} \\ P(X_1=x_1, \dots, X_n=x_n|\theta) & \text{discret} \end{cases}$$

Déf: Un modèle Bayésien est la donnée d'une loi conditionnelle et d'une loi à priori :

$$X|\theta \sim p(x|\theta), \quad \theta \sim p$$

Déf: Dans un modèle Bayésien, on appelle la loi à posteriori la loi de θ conditionnellement aux observations x (réalisation de X), notée

$$p(\theta|x) = \frac{p(x|\theta)p(\theta)}{p(x)} \quad \text{où } p(x) \text{ est la loi marginale de } X$$

| définie par $p(x) = \begin{cases} \int p(x|\theta)p(\theta)d\theta & \text{continu} \\ \sum_i p(x|\theta_i)p(\theta_i) & \text{discret} \end{cases}$

Les estimateurs Bayésiens du paramètre θ sont construits à partir de la loi a posteriori $p(\theta|x)$ par minimisation d'une fonction de coût appropriée.

On considère le coût quadratique :

$$\begin{aligned}
 C(\hat{\theta}) &= E((\hat{\theta} - \theta)^2 | x) \\
 &= E[((\hat{\theta} - E[\theta|x]) + (E[\theta|x] - \theta))^2 | x] \\
 &= E[(\hat{\theta} - E[\theta|x])^2 | x] + \text{Var}(\theta|x) \\
 &\geq \text{Var}(\theta|x)
 \end{aligned}$$

L'égalité est atteinte pour $\hat{\theta} = E[\theta|x]$

L'estimateur par la méthode Bayésienne est donc $E[\theta|x]$

► Étapes pour construire un estimateur Bayésien :

1. Choisir une loi a priori $p(\theta)$
2. Trouver la loi a posteriori $p(\theta|x)$
3. Poser $\hat{\theta} = E[\theta|x]$

2) Loi a priori conjuguée.

Comment choisir la loi a priori ?

- * Basé sur des expériences du passé ou sur une intuition du statisticien.
- * Basé sur la faisabilité des calculs.
- * Basé sur la volonté de n'apporter aucune information nouvelle pouvant biaiser l'estimation.

Déf.: Une famille F de lois sur Θ est dites conjuguée pour la loi $p(x|\theta)$ si pour tout $p(\cdot) \in F$, la loi a posteriori $p(\cdot|x)$ appartient également à F .

$$\text{Ex: } p(x|\theta) \sim \mathcal{B}(\theta)$$

$$p(x|\theta) = \prod_{i=1}^n \theta^{x_i} (1-\theta)^{1-x_i} = \theta^{\sum x_i} (1-\theta)^{n-\sum x_i}$$

$\prod_{i=1}^n$

On considère $\theta \sim \mathcal{B}(\alpha, \beta)$, $\alpha, \beta > 0$.

$$p(\theta) = \frac{\Gamma(\alpha+\beta)}{\Gamma(\alpha)\Gamma(\beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1} \mathbb{1}_{\theta \in (0,1)}$$

$$p(\theta|x) = \frac{p(x|\theta)p(\theta)}{p(x)} \leftarrow \int_0^1 p(x|\theta)p(\theta)d\theta$$

$$\alpha \theta^{\sum x_i + \alpha - 1} (1-\theta)^{n - \sum x_i + \beta - 1} \mathbb{1}_{\theta \in (0,1)}$$

$$\text{Donc } p(\theta|x) = \frac{\Gamma(\alpha+\beta+n)}{\Gamma(\alpha+\sum x_i)\Gamma(\beta+n-\sum x_i)} \theta^{\alpha+\sum x_i-1} (1-\theta)^{\beta+n-\sum x_i-1} \mathbb{1}_{\theta \in (0,1)}$$

C'est la densité de la loi $\mathcal{B}(\alpha + \sum x_i, \beta + n - \sum x_i)$

$X \sim \text{Beta}(\alpha, \beta)$, alors $E(X) = \frac{\alpha}{\alpha + \beta}$

L'estimateur Bayésien de θ est

$$\hat{\theta} = E(\theta | X) = \frac{\alpha + \sum X_i}{\alpha + \beta + n}$$

$$\rightarrow \text{Si } n \rightarrow \infty, \hat{\theta} \approx \frac{\frac{\alpha}{n} + \bar{X}_n}{\frac{\alpha + \beta}{n} + 1} \approx \bar{X}_n$$

$$\rightarrow \text{Si } n=0, \hat{\theta} = \frac{\alpha}{\alpha + \beta} = E[\text{Beta}(\alpha, \beta)]$$

Rq: On peut aussi construire des intervalles de confiance de θ à partir de la loi $p(\theta|x)$, ou faire des tests d'hypothèses.

Ex2: $p(\cdot | \theta) \sim N(\theta, \sigma^2)$ ^{connu}

$p(\cdot) \sim N(\mu_0, \sigma_0^2)$ à priori

$$p(x|\theta) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{\sum_{i=1}^n (x_i - \theta)^2}{2\sigma^2}\right)$$

$$p(\theta) = \frac{1}{\sqrt{2\pi}\sigma_0} \exp\left(-\frac{(\theta - \mu_0)^2}{2\sigma_0^2}\right)$$

Alors $p(\theta|x) \propto p(x|\theta)p(\theta)$

$$\propto \exp\left(-\left(\frac{n}{2\sigma^2} + \frac{1}{2\sigma_0^2}\right)\theta^2 + \left(\frac{\sum x_i}{\sigma^2} + \frac{\mu_0}{\sigma_0^2}\right)\theta\right)$$

$$\propto \exp\left(-\left(\frac{n}{\sum\sigma^2} + \frac{1}{\sum\sigma_0^2}\right)\left(\theta - \frac{\frac{\sum x_i}{\sigma^2} + \frac{\mu_0}{\sigma_0^2}}{\frac{n}{\sum\sigma^2} + \frac{1}{\sum\sigma_0^2}}\right)^2\right)$$

On reconnaît la densité d'une loi normale

$$N\left(\frac{\frac{\sum x_i}{\sigma^2} + \frac{\mu_0}{\sigma_0^2}}{\frac{n}{\sum\sigma^2} + \frac{1}{\sum\sigma_0^2}}, \frac{1}{\frac{n}{\sum\sigma^2} + \frac{1}{\sum\sigma_0^2}}\right)$$

$$\hat{\theta} = \bar{E}[\theta|x] = \frac{\frac{\sum_{i=1}^n x_i}{\sigma^2} + \frac{\mu_0}{\sigma_0^2}}{\frac{n}{\sum\sigma^2} + \frac{1}{\sum\sigma_0^2}}$$

3) Loi a priori de Jeffreys.

Si on ne sait pas une loi a priori informatif, on pense à la loi uniforme sur

W. Mais si $\theta \sim U(0,1)$, et on reparamétrise le modèle par $\phi = -\frac{1}{\lambda} \ln(1-\theta)$, alors $\phi \sim E(\lambda)$ (7)2), qui semble beaucoup plus informatif. On voit ainsi que une bonne notion de loi a priori non-informative est une loi améliorée par reparamétrisation.

Déf: La loi a priori de Jeffreys est donnée par

$$p(\theta) \propto \sqrt{I(\theta)}$$

avec $I(\theta) = \mathbb{E}[(\partial_\theta \ln p(x, \theta))^2]$

Cette loi possède 2 intérêts principaux:

* $I(\theta)$ est un indicateur de la quantité d'information apportée par le modèle $p(x, \theta)$, donc au niveau qualitatif - les valeurs de θ pour lesquelles $I(\theta)$ est plus grande doivent être plus probables

* La loi de Jeffreys est invariante par reparamétrisation. En effet,

Soit $\phi = h(\theta)$ avec h un C^1 -difféomorphisme.

$$\phi \text{ est de loi } \tilde{p}(\phi) = p(\phi) |(h^{-1})'(\phi)|$$

$$\text{De plus on a } \tilde{z}(\phi) = z(\phi) |(h^{-1})'(\phi)|^2$$

$$\text{Donc } \tilde{p}(\phi) \propto \sqrt{\tilde{z}(\phi)}$$