

# Statistiques mathématiques : cours 5

Guillaume Lécué

18 septembre 2017

# Aujourd'hui

Comparaison d'estimateurs

Optimalité de l'EMV

Borne de Cramer-Rao

Approche non-asymptotique de comparaison d'estimateurs

# Comparaison d'estimateurs dans les modèles paramétriques dominés

Modèle d'échantillonnage dominé paramétrique : on observe

$$X_1, \dots, X_n \stackrel{i.i.d.}{\sim} \mathbb{P}_\theta, \quad \theta \in \Theta \subset \mathbb{R}^d$$

où  $\mathbb{P}_\theta = f(\theta, \cdot) \cdot \mu$

Plusieurs estimateurs : moments,  $Z$ - et  $M$ -estimateurs, **EMV**

Question : Quel estimateur choisir ? comment comparer des estimateurs ?

# Vitesse de convergence et régions de confiance

$\hat{\theta}_n$  estimateur de  $\theta$ . Il y a deux types de résultats :

- ▶ vitesse de convergence **non-asymptotique** : à  $n$  fixé

$$\mathbb{E} [\|\hat{\theta}_n - \theta\|^2] \leq c_n(\theta)^2, \text{ (où } c_n(\theta) \downarrow 0)$$

- ▶ vitesse de convergence **asymptotiques** : quand  $n \rightarrow +\infty$ ,

$$v_n(\hat{\theta}_n - \theta) \xrightarrow{d} Z_\theta, \text{ (où } v_n^{-1} \downarrow 0)$$

Ces deux résultats permettent de construire des intervalles / régions de confiance (non-asymptotique / asymptotique).

Idee : La taille de ces régions de confiance caractérise la qualité d'estimation de  $\theta$  par  $\hat{\theta}_n$

# Régions de confiance : définition formelle

## Définition

Dans le modèle d'échantillonnage  $\{\mathbb{P}_\theta : \theta \in \Theta\}$  pour  $\Theta \subset \mathbb{R}^d$ . Soit  $\alpha \in (0, 1)$ . Pour tout  $n \geq 1$ , on considère un sous-ensemble observable  $\mathcal{C}_{n,\alpha} = \mathcal{C}_{n,\alpha}(X_1, \dots, X_n)$  de  $\mathbb{R}^d$ .  $\mathcal{C}_{n,\alpha}$  est appelé :

1. *région de confiance de niveau  $1 - \alpha$  quand*

$$\forall \theta \in \Theta : \mathbb{P}_\theta [\theta \in \mathcal{C}_{n,\alpha}] \geq 1 - \alpha$$

2. *région de confiance de niveau asymptotique  $1 - \alpha$  quand*

$$\forall \theta \in \Theta : \liminf_{n \rightarrow \infty} \mathbb{P}_\theta [\theta \in \mathcal{C}_{n,\alpha}] \geq 1 - \alpha.$$

# Comparaison d'estimateurs

Dans le modèle d'échantillonnage, comment **construire** le **meilleur** estimateur ? Dans quel sens ?

- ▶ Intuitivement :  $\hat{\theta}_n$  fournit une précision d'estimation de  $\theta$  optimale si on peut lui associer une **région de confiance de longueur / volume minimale** (à un niveau  $1 - \alpha$  donné).
- ▶ Différence entre point de vue **asymptotique** et **non-asymptotique**. Dans ce cours, nous étudions le point de vue asymptotique :
  - ▶ **vitesse de convergence asymptotique**
  - ▶ **variance asymptotique**

et on donne une brève initiation à la notion d'optimalité en non-asymptotique.

# Approche asymptotique

Hypothèse :  $\theta \in \Theta \subset \mathbb{R}$  et on se restreint aux estimateurs  $\hat{\theta}_n$   
asymptotiquement normaux :

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{d} \mathcal{N}(0, v(\theta))$$

(théorèmes limites pour les  $Z$ -,  $M$ -estimateurs, EMV, plug-in)

Intuitivement : on a

$$\hat{\theta}_n \approx \theta + \sqrt{\frac{v(\theta)}{n}} \mathcal{N}(0, 1)$$

Donc la variance asymptotique mesure :

1. l' "incertitude" de l'estimation de  $\theta$  par  $\hat{\theta}_n$
2. la taille des régions de confiance asymptotiques

# efficacité asymptotique

## Définition

Soit  $\hat{\theta}_{n,1}$  et  $\hat{\theta}_{n,2}$  deux estimateurs asymptotiquement normaux de variance asymptotique respectives  $v_1(\theta)$  et  $v_2(\theta)$ . On dit que  $\hat{\theta}_{n,1}$  est **plus efficace** que  $\hat{\theta}_{n,2}$  quand :

$$v_1(\theta) \leq v_2(\theta) \text{ pour tout } \theta \in \Theta$$

Un estimateur est **asymptotiquement efficace** s'il n'existe pas d'autre estimateur (dans la classe considérée) plus efficace que lui.

- ▶ on ne compare que les estimateurs asymptotiquement normaux (de vitesse de convergence en  $1/\sqrt{n}$ )
- ▶ cela exclut les estimateurs pathologique comme  $\hat{\theta}_n = \theta_0$



# Efficacité asymptotique de l'EMV

- ▶ Cadre : modèle d'échantillonnage dominé paramétrique

$$X_1, \dots, X_n \stackrel{i.i.d.}{\sim} \mathbb{P}_\theta = f(\theta, \cdot) \cdot \mu \text{ pour } \theta \in \Theta \subset \mathbb{R}$$

- ▶ Hypothèse : la quantité

$$\mathbb{I}(\theta) = \mathbb{E}_\theta \left[ (\partial_\theta \log f(\theta, X_1))^2 \right]$$

est bien définie. C'est l'**information de Fisher** du modèle  $\{\mathbb{P}_\theta, \theta \in \Theta\}$  en  $\theta$ .

## Définition

La famille de densités  $\{f(\theta, \cdot), \theta \in \Theta\}$ , par rapport à la mesure dominante  $\mu$ , et  $\Theta \subset \mathbb{R}$  ouvert, est *régulière* si

- ▶  $\{f(\theta, \cdot) > 0\} = \{f(\theta', \cdot) > 0\}$ ,  $\mu$ -p.p.  $\forall \theta, \theta' \in \Theta$
- ▶  $\mu$ -p.p.  $\theta \mapsto f(\theta, \cdot)$ ,  $\theta \mapsto \log f(\theta, \cdot)$  sont  $\mathcal{C}^2$
- ▶  $\forall \theta \in \Theta, \exists \mathcal{V}_\theta \subset \Theta$  t.q. pour tout  $a \in \mathcal{V}_\theta$

$$|\partial_a^2 \log f(a, x)| + |\partial_a \log f(a, x)| + (\partial_a \log f(a, x))^2 \leq g(x)$$

$$\text{où } \int_{\mathbb{R}} g(x) \sup_{a \in \mathcal{V}(\theta)} f(a, x) \mu(dx) < +\infty$$

- ▶ L'information de Fisher est non-dégénérée :

$$\forall \theta \in \Theta, \mathbb{I}(\theta) > 0.$$

# Résultat principal

## Theorem

Dans le modèle d'échantillonnage dominé (pour  $\Theta \subset \mathbb{R}$ ) tel que  $\{\mathbb{P}_\theta, \theta \in \Theta\}$  est *régulier* on a :

- ▶ l'EMV est asymptotiquement normal :

$$\sqrt{n}(\hat{\theta}_n^{\text{mv}} - \theta) \xrightarrow{d} \mathcal{N}\left(0, \frac{1}{\mathbb{I}(\theta)}\right)$$

- ▶ Si  $\hat{\theta}_n$  est un Z-estimateur associé à  $\phi$  "régulière", c-à-d tel que  $\hat{\theta}_n$  est a.n. de variance asymptotique

$$v(\theta) = \frac{\mathbb{E}_\theta[\phi(\theta, X)^2]}{(\mathbb{E}_\theta[\partial_\theta \phi(\theta, X)])^2} \text{ alors } \boxed{\forall \theta \in \Theta, v(\theta) \geq \frac{1}{\mathbb{I}(\theta)}}$$

Donc l'EMV est asymptotiquement efficace parmi les Z-estimateurs réguliers

# Preuve de l'efficacité asymptotique de l'EMV parmi les Z-estimateurs réguliers

Soit  $\hat{\theta}_n$  un Z-estimateur régulier associé à la fonction  $\phi$ , alors, sa variance asymptotique vaut

$$v_\phi(\theta) = \frac{\mathbb{E}_\theta [\phi(\theta, X)^2]}{(\mathbb{E}_\theta [\partial_\theta \phi(\theta, X)])^2}$$

A montrer : pour toute fonction  $\phi$  (régulière) :

$$\boxed{\frac{\mathbb{E}_\theta [\phi(\theta, X)^2]}{(\mathbb{E}_\theta [\partial_\theta \phi(\theta, X)])^2} \geq \frac{1}{\mathbb{I}(\theta)}}$$

# Preuve de l'inégalité (1/2)

- ▶ Par construction de  $\phi$ , on a  $\forall \theta \in \Theta, \mathbb{E}_\theta \phi(\theta, X) = 0$  alors

$$F'(\theta) = 0 \text{ où } F(\theta) = \mathbb{E}_\theta [\phi(\theta, X)] = 0$$

- ▶ càd

$$\begin{aligned} 0 &= \int_{\mathbb{R}} [\partial_\theta \phi(\theta, x) f(\theta, x) + \phi(\theta, x) \partial_\theta f(\theta, x)] \mu(dx) \\ &= \int_{\mathbb{R}} [\partial_\theta \phi(\theta, x) f(\theta, x) + \phi(\theta, x) \partial_\theta \log f(\theta, x) f(\theta, x)] \mu(dx) \end{aligned}$$

- ▶ Conclusion

$$\mathbb{E}_\theta [\partial_\theta \phi(\theta, X)] = - \mathbb{E}_\theta [\phi(\theta, X) \partial_\theta \log f(\theta, X)]$$

## Preuve de l'inégalité (2/2)

- ▶ On a

$$\mathbb{E}_\theta [\partial_\theta \phi(\theta, \mathbf{X})] = -\mathbb{E}_\theta [\phi(\theta, \mathbf{X}) \partial_\theta \log f(\theta, \mathbf{X})]$$

- ▶ Cauchy-Schwarz :

$$(\mathbb{E}_\theta [\partial_\theta \phi(\theta, \mathbf{X})])^2 \leq \mathbb{E}_\theta [\phi(\theta, \mathbf{X})^2] \mathbb{E}_\theta [(\partial_\theta \log f(\theta, \mathbf{X}))^2],$$

c'est-à-dire

$$\boxed{v_\phi(\theta) = \frac{\mathbb{E}_\theta [\phi(\theta, \mathbf{X})^2]}{(\mathbb{E}_\theta [\partial_\theta \phi(\theta, \mathbf{X})])^2} \geq \frac{1}{\mathbb{I}(\theta)}}$$

# Information de Fisher et résultats non-asymptotiques : borne de Cramer-Rao



## Borne de Cramer-Rao

Soit  $Z$  une observation de l'expérience  $(\mathfrak{Z}, \mathcal{Z}, \{\mathbb{P}_\theta : \theta \in \Theta\})$  où

1.  $\Theta$  est un ouvert de  $\mathbb{R}$
2.  $\mathbb{P}_\theta = f(\theta, \cdot) \cdot \mu$  (modèle dominé par  $\mu$ )
3. le modèle  $\{\mathbb{P}_\theta : \theta \in \Theta\}$  est régulier et on note l'information de Fisher par :

$$\mathbb{I}(\theta) = \mathbb{E}_\theta [(\partial_1 \log f(\theta, Z))^2]$$

Alors pour tout estimateur  $\hat{\theta}$ , on a

$$\mathbb{E}_\theta (\hat{\theta} - \theta)^2 \geq \frac{(1 + b'(\theta))^2}{\mathbb{I}(\theta)} + b(\theta)^2$$

où  $b(\theta) = \mathbb{E}_\theta \hat{\theta}(Z) - \theta$  est le biais de  $\hat{\theta}$ .

En particulier, si l'estimateur  $\hat{\theta}$  est sans biais alors son risque quadratique est plus grand que  $\mathbb{I}(\theta)^{-1}$ .

## Mise en perspective de Cramer-Rao

Le résultat de l'efficacité asymptotique de l'EMV parmi les  $Z$ -estimateurs réguliers dit que si  $\hat{\theta}_n$  est un  $Z$ -estimateur régulier alors

$$\hat{\theta}_n \approx \theta + \sqrt{\frac{v_\phi(\theta)}{n}} \mathcal{N}(0, 1) \text{ où } v_\phi(\theta) \geq \frac{1}{\mathbb{I}(\theta)}$$

alors, intuitivement,

$$\mathbb{E}_\theta (\hat{\theta}_n - \theta)^2 \approx \frac{v_\phi(\theta)}{n} \geq \frac{1}{n\mathbb{I}(\theta)} = \frac{1}{\mathbb{I}(\theta|\mathcal{E}^n)}$$

On retrouve donc la version "asymptotique" de Cramer-Rao pour les  $Z$ -estimateurs réguliers (qui sont "asymptotiquement sans biais" car consistant).

# Preuve de Cramer-Rao

On note :

- ▶  $R_\theta(\hat{\theta}) = \mathbb{E}_\theta (\hat{\theta} - \theta)^2$  : le risque quadratique de  $\hat{\theta}$
- ▶  $b(\theta) = \mathbb{E}_\theta \hat{\theta}(Z) - \theta$  : le biais de  $\hat{\theta}$
- ▶  $\ell(\theta, z) = \log f(\theta, z)$  : le score de  $\theta$  en  $z$

Montrer que :

1.  $R_\theta(\hat{\theta}) = b(\theta)^2 + \text{var}_\theta(\hat{\theta})$  (décomposition biais/variance)
2.  $\mathbb{E}_\theta \partial_\theta \ell(\theta, Z) = 0$
3.  $b'(\theta) = \mathbb{E}_\theta [\hat{\theta}(Z) \partial_\theta \ell(\theta, Z)] - 1$
4.  $1 + b'(\theta) = \mathbb{E}_\theta [(\hat{\theta} - \mathbb{E}_\theta \hat{\theta}) \partial_\theta \ell(\theta, Z)]$
5. en déduire la borne de Cramer-Rao

# Approche non-asymptotique de comparaison d'estimateurs

# Risque quadratique

## Définition

Soit  $Z$  une observation de l'expérience  $(\mathfrak{Z}, \mathcal{Z}, \{\mathbb{P}_\theta : \theta \in \Theta\})$  pour  $\Theta \subset \mathbb{R}$ .

1. Soit  $\hat{\theta} = \hat{\theta}(Z)$  un estimateur. On appelle *risque quadratique* de  $\hat{\theta}$  au point  $\theta \in \Theta$  :

$$\mathcal{R}(\hat{\theta}_n, \theta) = \mathbb{E}_\theta [(\hat{\theta} - \theta)^2]$$

2. Soient  $\hat{\theta}_1, \hat{\theta}_2$  deux estimateurs. On dit que  $\hat{\theta}_1$  est *préférable au sens du risque quadratique* à  $\hat{\theta}_2$  quand

$$\forall \theta \in \Theta, \mathcal{R}(\hat{\theta}_1, \theta) \leq \mathcal{R}(\hat{\theta}_2, \theta)$$

# Absence d'optimalité (1/3)

Question : Existe-t-il un estimateur **optimal**  $\theta^*$  au sens où

$$\forall \theta \in \Theta, \mathcal{R}(\theta^*, \theta) \leq \inf_{\hat{\theta}} \mathcal{R}(\hat{\theta}_n, \theta) ?$$

## Proposition

Si  $\Theta = \{\theta_1, \theta_2\}$  et *s'il n'existe pas d'événement observable*  $A \in \mathcal{Z}$  tel que, *simultanément* :

$$\mathbb{P}_{\theta_1} [A] = 0 \text{ et } \mathbb{P}_{\theta_2} [A] = 1,$$

(on dit que  $\mathbb{P}_{\theta_1}$  et  $\mathbb{P}_{\theta_2}$  ne sont *pas étrangères*), alors *il n'existe pas d'estimateur optimal*

## Absence d'optimalité (2/3)

- ▶ Preuve : Pour tout estimateur  $\theta^*$ , on a

$$\max \{ \mathcal{R}(\theta^*, \theta_1), \mathcal{R}(\theta^*, \theta_2) \} > 0 \quad (*)$$

- ▶ Supposons  $\theta^*$  estimateur optimal et  $\mathcal{R}(\theta^*, \theta_1) > 0$ . Alors  $\hat{\theta}^{\text{trivial}} := \theta_1$  vérifie

$$0 = \mathcal{R}(\hat{\theta}^{\text{trivial}}, \theta_1) < \mathcal{R}(\theta^*, \theta_1) \quad \text{contradiction !}$$

ceci contredit l'optimalité de  $\theta^*$

## Absence d'optimalité (3/3)

Preuve de  $(\star)$  : si  $\mathcal{R}(\theta^*, \theta_1) = \mathcal{R}(\theta^*, \theta_2) = 0$ , alors

$$\theta^* = \theta_1 \quad \mathbb{P}_{\theta_1} \text{-p.s.} \quad \text{et} \quad \theta^* = \theta_2 \quad \mathbb{P}_{\theta_2} \text{-p.s..}$$

Soient

$$A = \{z \in \mathfrak{Z} : \theta^*(z) = \theta_1\} \text{ et } B = \{z \in \mathfrak{Z} : \theta^*(z) = \theta_2\}$$

Alors  $\mathbb{P}_{\theta_1}[A] = 1$  et donc  $\mathbb{P}_{\theta_2}[A] > 0$ . Aussi,  $\mathbb{P}_{\theta_2}[B] = 1$ . Donc  $A \cap B \neq \emptyset$ .

Alors il existe  $z_0 \in \mathfrak{Z}$  tel que  $\theta_1 = \theta^*(z_0) = \theta_2$  : **contradiction !**



# Notions d'optimalité non-asymptotique

- ▶ **Différentes notions existent.** Deux exemples extrêmes :

## Définition (Admissibilité et critère minimax)

- ▶ Un estimateur  $\theta^*$  est **admissible** s'il **n'existe pas** d'estimateur  $\hat{\theta}$  **préférable** à  $\theta^*$  c'à d tel que, pour **tout**  $\theta \in \Theta$ ,

$$\mathcal{R}(\hat{\theta}, \theta) < \mathcal{R}(\theta^*, \theta).$$

- ▶ Un estimateur  $\theta^*$  est **minimax** si

$$\sup_{\theta \in \Theta} \mathcal{R}(\theta^*, \theta) = \inf_{\hat{\theta}} \sup_{\theta \in \Theta} \mathcal{R}(\hat{\theta}, \theta)$$

- ▶ **Admissibilité** : permet d'éliminer des estimateurs absurdes (mais pas tous :  $\hat{\theta}_n = \theta_0$ )
- ▶ **Minimaxité** : notion très **robuste mais conservatrice**

exemple : propriété minimax de la moyenne empirique

cadre :  $X_1, \dots, X_n \stackrel{i.i.d.}{\sim} \mathcal{N}(\theta, 1)$  pour  $\theta \in \mathbb{R}$

1. la moyenne empirique  $\bar{X}_n$  est sans biais et vérifie :

$$\mathcal{R}(\bar{X}_n, \theta) = \frac{1}{n}$$

2. soit  $\hat{\theta}_n$  un estimateur sans biais ; par Cramer-Rao, on a :

$$\mathcal{R}(\hat{\theta}_n, \theta) \geq \frac{1}{n}$$

La moyenne empirique est donc **minimax parmi les estimateurs sans biais** dans le modèle  $\{\mathcal{N}(\theta, 1) : \theta \in \mathbb{R}\}$