

# Estimateurs obtenus par maximisation ou annulation d'un critère empirique

Lionel Truquet,  
`lionel.truquet@ensai.fr`

## 1 Maximisation ou annulation d'un critère

- M-estimateurs
- Z-estimateurs

## 2 Consistance

- Consistance des  $M$ -estimateurs
- Consistance des  $Z$ -estimateurs

## 3 Normalité asymptotique

## 1 Maximisation ou annulation d'un critère

- M-estimateurs
- Z-estimateurs

## 2 Consistance

- Consistance des  $M$ -estimateurs
- Consistance des  $Z$ -estimateurs

## 3 Normalité asymptotique

# Notations

On dispose de  $n$  observations  $x_1, \dots, x_n$  d'un même phénomène. On suppose que ces valeurs sont des éléments d'un espace mesurable  $(G, \mathcal{G})$ , le cas  $G = \mathbb{R}^d$  permet de fixer les idées.

- On considère que ces valeurs sont des réalisations de  $n$  variables aléatoires i.i.d. dont la loi dépend d'un paramètre  $\theta \in \Theta$  que l'on cherche à estimer.  $\Theta \subset \mathbb{R}^k$  le plus souvent dans ce qui suit.
- Pour cela, on se donne une famille de mesures de probabilité  $\mathcal{P}$  sur  $(G, \mathcal{G})$ . Le triplet  $(G^n, \mathcal{G}^{\otimes n}, \{P^{\otimes n} : P \in \mathcal{P}\})$  est appelé modèle statistique. On posera  $X_i(\omega) = \omega_i$  pour  $1 \leq i \leq n$ .
- On suppose que  $\theta = \theta(P)$  est le paramètre à estimer. On supposera que  $(x_1, \dots, x_n)$  est une réalisation de  $P_0 \in \mathcal{P}$  et notera  $\theta_0 = \theta(P_0)$ .
- On admettra que pour tout  $P \in \mathcal{P}$ , il existe une unique mesure de probabilité  $\mathbb{P}^\infty$  sur  $G^\infty$  telle que pour tout  $n \geq 1$  et  $A_1, \dots, A_n \in \mathcal{G}$ ,

$$\mathbb{P}^\infty(X_1 \in A_1, \dots, X_n \in A_n) = \prod_{i=1}^n P(A_i).$$

On notera  $\mathbb{P} = \mathbb{P}_0^\infty$ .

## 1 Maximisation ou annulation d'un critère

- M-estimateurs
- Z-estimateurs

## 2 Consistance

- Consistance des  $M$ -estimateurs
- Consistance des  $Z$ -estimateurs

## 3 Normalité asymptotique

# Contexte général

- On se donne une famille de fonctions mesurables  $\{m_\theta : G \rightarrow \mathbb{R}, \theta \in \Theta\}$ . Un estimateur  $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$  est obtenu en maximisant

$$\theta \mapsto M_n(\theta) := \frac{1}{n} \sum_{i=1}^n m_\theta(X_i).$$

- Pour que cette approche soit pertinente, il faut que la fonction  $\theta \mapsto \mathbb{E}[m_\theta(X_1)]$  soit maximale en  $\theta = \theta_0$ . On espère ainsi que  $\hat{\theta}_n$  ne soit pas trop éloigné de  $\theta_0$  (loi des grands nombres).
- L'exemple le plus simple est celui de la moyenne empirique  $\bar{X}_n$  qui est un M-estimateur pour  $m_\theta(x) = -(x - \theta)^2$ . C'est plus simplement un estimateur obtenu par la méthode des moments.
- L'estimateur du maximum de vraisemblance où  $\mathcal{P} = \{p_\theta(x)\mu(dx) : \theta \in \Theta\}$  et  $m_\theta(x) = \log p_\theta(x)$ .

## 1 Maximisation ou annulation d'un critère

- M-estimateurs
- Z-estimateurs

## 2 Consistance

- Consistance des  $M$ -estimateurs
- Consistance des  $Z$ -estimateurs

## 3 Normalité asymptotique

# Définition

- Il s'agit de définir des estimateurs qui annule  $Z_n : \theta \mapsto \frac{1}{n} \sum_{i=1}^n z_\theta(X_i)$ . Si l'estimateur  $\theta$  a  $k$  coordonnées,  $z_\theta$  a souvent  $k$  fonctions coordonnées.
- Etudier un  $M$ -estimateur peut se ramener à étudier un  $Z$ -estimateur lorsque  $\theta \mapsto m_\theta(x)$  est différentiable pour tout  $x$ . On a alors  $z_\theta(x) = \dot{m}_\theta(x)$  (gradient de  $\theta \mapsto m_\theta(x)$  au point  $\theta$ ).
- On peut avoir des  $M$ -estimateurs qui ne s'associe pas directement à un  $Z$ -estimateur. C'est le cas, par exemple lorsque  $m_\theta(x) = \log \mathbb{1}_{[0,\theta]}(x) - \log(\theta)$  (max. de vraisemblance lorsque la loi est la loi uniforme sur  $[0, \theta]$ ).
- Estimateurs de localisation. Correspond au cas  $z_\theta(x) = z(x - \theta)$ . Par exemple,
  - $z(y) = y$  (estimation de la moyenne),
  - $z(y) = \text{sign}(y)$  (estimation de la médiane),
  - $z(y) = -k\mathbb{1}_{y \leq -k} + y\mathbb{1}_{|y| < k} + k\mathbb{1}_{y \geq k}$  (estimateurs de Huber).On définit  $\text{sign}(y) = -\mathbb{1}_{y < 0} + \mathbb{1}_{y > 0}$ .



## 1 Maximisation ou annulation d'un critère

- M-estimateurs
- Z-estimateurs

## 2 Consistance

- Consistance des  $M$ -estimateurs
- Consistance des  $Z$ -estimateurs

## 3 Normalité asymptotique

- 1 Maximisation ou annulation d'un critère
  - M-estimateurs
  - Z-estimateurs
- 2 Consistance
  - Consistance des  $M$ -estimateurs
  - Consistance des  $Z$ -estimateurs
- 3 Normalité asymptotique

# Consistance faible

## Definition 1

On dira que  $\hat{\theta}_n$  est faiblement consistant si  $\hat{\theta}_n \xrightarrow{P} \theta_0$ .

On pose  $M(\theta) = \mathbb{E}m_\theta(X_1)$ .

## Theorem 1

On suppose que

- 1  $\sup_{\theta \in \Theta} |M_n(\theta) - M(\theta)| \xrightarrow{P} 0$ ,
- 2  $\forall \epsilon > 0, \sup_{\theta: d(\theta, \theta_0) \geq \epsilon} M(\theta) < M(\theta_0)$ .

Alors toute suite d'estimateurs telle que  $M_n(\hat{\theta}_n) \geq \sup_{\theta \in \Theta} M_n(\theta) - o_{\mathbb{P}}(1)$  est faiblement consistante.

- La condition 1 est une loi (faible) des grands nombres uniforme.
- Si  $\theta$  est compact  $M$  est continue, alors la condition 2 est vérifiée. Cette condition demande une "bonne séparation" du point maximum.

# Consistance forte

## Definition 2

On dira que  $\hat{\theta}_n$  est fortement consistant si  $\lim_{n \rightarrow \infty} \hat{\theta}_n = \theta_0$  p.s.

## Theorem 2

On suppose

- 1  $\Theta$  compact,
- 2  $\theta \mapsto m_\theta(x)$  continue pour presque tout  $x$  et  $\mathbb{E} \sup_{\theta \in \Theta} m_\theta(X_1) < \infty$ ,
- 3  $\theta \mapsto M(\theta)$  est maximisée en  $\theta_0$  et  $M(\theta) = M(\theta_0) \Rightarrow \theta = \theta_0$ .

Alors si  $\hat{\theta}_n = \arg \max_{\theta \in \Theta} M_n(\theta)$ ,  $\hat{\theta}_n$  est fortement consistant.

La preuve est basé sur le lemme suivant.

## Lemma 1

Si les conditions 1 et 2 du théorème précédent sont vérifiées, alors

$\lim_{n \rightarrow \infty} \sup_{\theta \in \Theta} |M_n(\theta) - M(\theta)| = 0$  p.s.

# Cas du maximum de vraisemblance, condition d'identifiabilité

- On suppose ici que  $m_\theta(x) = \log \frac{p_\theta}{p_{\theta_0}}(x)$  et  $p_{\theta_0}$  désigne la densité des observations par rapport à la mesure de référence  $\mu$ .
- Maximiser la vraisemblance est équivalent à la maximisation de  $M_n(\theta) = \frac{1}{n} \sum_{i=1}^n m_\theta(X_i)$ .
- Si  $dP = p d\mu$  et  $dQ = q d\mu$ , la quantité  $K(P, Q) = \int_{p>0} \log\left(\frac{p}{q}\right) p d\mu$  est appelée divergence de Kullback entre  $P$  et  $Q$ . Il s'agit d'une quantité positive, éventuellement égale à  $+\infty$ . Ce n'est pas une distance, mais elle caractérise la déviation de  $Q$  par rapport à  $P$ .

Ici  $M(\theta)$  est l'opposé de la divergence de Kullback entre  $p_\theta d\mu$  et  $p_{\theta_0} d\mu$ .

## Lemma 2

Supposons que si  $\theta \neq \theta_0$ , alors  $\mu(\{p_{\theta_0} \neq p_\theta\}) > 0$ . Alors  $M$  atteint un unique maximum en  $\theta_0$ .

- 1 Maximisation ou annulation d'un critère
  - M-estimateurs
  - Z-estimateurs
- 2 Consistance
  - Consistance des  $M$ -estimateurs
  - Consistance des  $Z$ -estimateurs
- 3 Normalité asymptotique

# Consistance faible

Un zéro de  $\theta \mapsto Z_n(\theta)$  est un maximiseur de  $\theta \mapsto -\|Z_n(\theta)\|$ . Le résultat suivant est alors immédiat.

## Theorem 3

*On suppose les deux conditions suivantes satisfaites.*

- 1  $\sup_{\theta \in \Theta} \|Z_n(\theta) - Z(\theta)\| = o_P(1)$ .
- 2 *Pour tout  $\epsilon > 0$ ,  $\inf_{\theta: d(\theta, \theta_0) > \epsilon} \|Z(\theta)\| > 0 = \|Z(\theta_0)\|$ .*

*Alors tout estimateur  $\hat{\theta}_n$  tel que  $Z_n(\hat{\theta}_n) = o_P(1)$  est faiblement consistant.*

On peut aussi énoncer des résultats de consistance forte en rajoutant de la compacité comme pour les M-estimateurs.

# Exemple de la médiane

Si  $z(x) = \text{sign}(x)$ , on suppose que  $\theta \mapsto Z(\theta)$  admet un zéro seulement en  $\theta_0$ . Montrer la consistance du  $Z$ -estimateur. On pourra utiliser le lemme suivant.

## Lemma 3

*Si  $X_1, X_2, \dots$  sont i.i.d. de fonction de répartition  $F$  et  $\mathbb{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{X_i \leq x}$ , alors  $\lim_{n \rightarrow \infty} \sup_{x \in \mathbb{R}} |\mathbb{F}_n(x) - F(x)| = 0$  p.s.*

Il est aussi possible de voir la médiane empirique comme un  $M$ -estimateur, avec  $m_\theta(x) = |x - \theta|$ .



- 1 Lorsque  $p_\theta(x) = (1 + (x - \theta)^2)^{-1}$  pour  $x \in \mathbb{R}$  (loi de Cauchy), prouver la consistance du maximum de vraisemblance lorsque  $\Theta$  est un compact de  $\mathbb{R}$ .
- 2 Considérons le modèle de régression non linéaire  $Y_i = g_\theta(W_i) + \varepsilon_i$  avec  $((W_i, \varepsilon_i))_{1 \leq i \leq n}$  i.i.d. telle que  $\mathbb{E}\varepsilon_1^2 < \infty$  et  $\mathbb{E}(\varepsilon_i | W_i) = 0$ . Lorsque les observations sont  $X_i = (Y_i, W_i)$  pour  $1 \leq i \leq n$ , discuter la consistance d'un  $M$ -estimateur bien choisi.

- 1 Maximisation ou annulation d'un critère
  - M-estimateurs
  - Z-estimateurs
- 2 Consistance
  - Consistance des  $M$ -estimateurs
  - Consistance des  $Z$ -estimateurs
- 3 Normalité asymptotique

# Résultat pour les $Z$ -estimateurs

Pour une fonction  $f : \mathbb{R}^k \rightarrow \mathbb{R}^k$ , on note par  $\dot{f}(x)$  la matrice différentielle de  $f$  au point  $x$ .

## Theorem 4

- 1 Pour tout  $x$ ,  $\theta \mapsto z_\theta(x)$  est continûment différentiable.
- 2  $\mathbb{E}z_{\theta_0}(X_1) = 0$ ,  $\mathbb{E}\|z_{\theta_0}(X_1)\|^2 < \infty$ . De plus,  $\mathbb{E}\dot{z}_{\theta_0}(X_1)$  existe (intégrabilité) et est inversible.
- 3 Il existe une fonction positive  $\alpha$  tel que  $\mathbb{E}\alpha(X_1) < \infty$  ainsi qu'un voisinage  $\mathcal{V}_{\theta_0}$  de  $\theta_0$  tel que pour tout  $\theta \in \mathcal{V}_{\theta_0}$  et tout  $x$ ,

$$\left| \frac{\partial z_{\theta,h}(x)}{\partial \theta_i} \right| \leq \alpha(x), \quad 1 \leq i, h \leq k.$$

Alors toute suite d'estimateurs  $\hat{\theta}_n$  consistante et telle que  $Z_n(\hat{\theta}_n) = o_{\mathbb{P}}(1/\sqrt{n})$  vérifie

$$\sqrt{n}(\hat{\theta}_n - \theta_0) = -(\mathbb{E}\dot{z}_{\theta_0}(X_1))^{-1} \frac{1}{\sqrt{n}} \sum_{i=1}^n z_{\theta_0}(X_i) + o_{\mathbb{P}}(1) \Rightarrow \mathcal{N}_k(0, W_{\theta_0}^{-1} V_{\theta_0} W_{\theta_0}^{-1}),$$

avec  $W_{\theta_0} = \mathbb{E}\dot{z}_{\theta_0}(X_1)$ ,  $V_{\theta_0} = \mathbb{E}z_{\theta_0}(X_1)z_{\theta_0}(X_1)'$ .

# Application au M-estimateurs

On donne maintenant une conséquence pour les M-estimateurs dans le cadre compact.

## Theorem 5

- 1  $\Theta$  est un compact de  $\mathbb{R}^k$  qui contient  $\theta_0$  dans son intérieur.
- 2  $\theta \mapsto \mathbb{E}m_\theta(X_1)$  est uniquement maximisée en  $\theta = \theta_0$  et  $\sup_{\theta \in \Theta} |m_\theta(X_1)|$  est intégrable.
- 3  $\theta \mapsto m_\theta(x)$  est deux fois continûment différentiable. De plus, il existe un voisinage  $\mathcal{V}_{\theta_0}$  de  $\theta_0$  tel que  $\sup_{\theta \in \mathcal{V}_{\theta_0}} \|\ddot{m}_\theta(X_1)\|$  est intégrable.
- 4  $\dot{m}_{\theta_0}(X_1)$  est de carré intégrable et  $\mathbb{E}[\dot{m}_{\theta_0}(X_1)]$  est inversible.

Alors,  $\sqrt{n}(\hat{\theta}_n - \theta_0) \Rightarrow \mathcal{N}_k(0, W_{\theta_0}^{-1} V_{\theta_0} W_{\theta_0}^{-1})$  avec

$$W_{\theta_0} = \mathbb{E}\dot{m}_{\theta_0}(X_1), \quad V_{\theta_0} = \mathbb{E}\dot{m}_{\theta_0}(X_1)\dot{m}_{\theta_0}(X_1)'$$

# Le cas de l'estimateur du maximum de vraisemblance (EMV)

- Correspond au cas  $m_\theta(x) = \log p_\theta(x)$ .
- Sous certaines conditions de régularité et d'intégrabilité pour  $\theta \mapsto m_\theta(x)$  et ses dérivées, on a normalité asymptotique d'une suite consistante de  $M$ -estimateurs.
- On a aussi l'égalité  $W_{\theta_0} = -V_{\theta_0}$  et la valeur commune, notée  $I_{\theta_0}$  est appelée information de Fisher au point  $\theta_0$ . On a alors

$$I_{\theta_0} = \mathbb{E} \left( \frac{\dot{p}_{\theta_0}(X_1) \dot{p}_{\theta_0}(X_1)'}{p_{\theta_0}(X_1)^2} \right) = \mathbb{E} \left( \frac{\ddot{p}_{\theta_0}(X_1)}{p_{\theta_0}(X_1)} \right).$$

- $I_{\theta_0}$  s'interprète comme la courbure moyenne de l'opposé de la log-vraisemblance. Plus cette quantité est grande, plus la variance asymptotique de l'EMV est faible. Intuitivement,  $\theta_0$  peut être estimé plus précisément.

# Deux remarques sur l'EMV

- Dans le cas où les données suivent une loi uniforme sur l'intervalle  $[0, \theta_0]$  avec  $\theta_0$  inconnu, les conditions de régularité précédentes ne sont pas satisfaites. L'EMV est  $\hat{\theta}_n = \max_{1 \leq i \leq n} X_i$  et  $n(\theta_0 - \hat{\theta}_n) \Rightarrow \mathcal{E}(1/\theta_0)$ . Le comportement de l'EMV n'est donc pas standard.
- Si la densité  $p$  des données n'est pas dans  $\{p_\theta : \theta \in \Theta\}$ , et si les conditions de régularité sont satisfaites, il est toujours possible de montrer que  $\sqrt{n}(\hat{\theta}_n - \theta_0)$  est asymptotiquement Gaussien, où  $\theta_0$  est l'unique minimiseur de  $\theta \mapsto -\mathbb{E} \log \frac{p_\theta(X_1)}{p(X_1)}$ . On peut interpréter  $p_{\theta_0}$  comme une projection de la densité sur le modèle choisi et  $p_{\hat{\theta}_n}$  est alors une raisonnable approximation de cette projection.

# Example 1 : loi de Weibull

$$p_{\lambda,\sigma}(x) = \frac{\lambda}{\sigma} x^{\lambda-1} \exp\left(-\frac{x^\lambda}{\sigma}\right), \quad x > 0, \lambda > 0, \sigma > 0.$$

Vérifier la consistance et la normalité asymptotique de l'EMV lorsque  $\theta_0$  est dans l'intérieur d'un compact  $\Theta$  de  $]0, \infty[^2$ .

## Exemple 2 : la régression logistique

On suppose observé un échantillon  $(X_1, Y_1), \dots, (X_n, Y_n)$  de variables aléatoires à valeurs dans  $\{0, 1\} \times \mathbb{R}^k$  et tel que

$$\mathbb{P}(Y_i = 1 | X_i = x) = F(\theta'_0 x)$$

avec  $F(x) = \frac{\exp(x)}{1 + \exp(x)}$ .

Vérifier la consistance et la normalité asymptotique de l'EMV lorsque  $\theta_0$  est dans l'intérieur d'un compact  $\Theta$  de  $\mathbb{R}^k$ .