

L3 Economie

Statistiques inférentielles

Chapitre 3 : Estimation ponctuelle

Cécile Durot
cecile.durot@gmail.com

Université Paris Nanterre

Introduction

Méthode de substitution

Estimation non paramétrique : Estimation empirique

Estimation paramétrique : EMV

Cadre d'étude

Dans toute la suite, nous supposons que les données collectées sont des nombres réels x_1, \dots, x_n , et que le procédé de collecte est suffisamment proche du tirage aléatoire simple pour que l'on puisse supposer que :

Les données x_1, \dots, x_n sont les réalisations de v.a.r. X_1, \dots, X_n indépendantes et de même loi (i.i.d.).

On notera respectivement P_X et F_X la loi et la fonction de répartition commune des v.a.r. X_1, \dots, X_n tandis que P_n et F_n désigneront respectivement la loi empirique et la fonction de répartition empirique. On notera également X une variable aléatoire abstraite de même loi que X_1, \dots, X_n et Ω l'univers sur lequel sont définies X_1, \dots, X_n .

Problématique

On s'intéresse à une caractéristique de la loi P_X . La caractéristique est inconnue puisque la loi est inconnue. Pour simplifier, on considère principalement ici le cas d'une caractéristique à valeurs réelles ; on l'appellera **paramètre d'intérêt**.

Exemples :

- Le paramètre d'intérêt peut être par exemple $P(X \leq 0)$, $P(X \leq 2)$, ou plus généralement $F_X(t)$ pour un $t \in \mathbb{R}$ donné.
- Si le modèle statistique suppose que X_1, \dots, X_n possèdent une espérance, le paramètre d'intérêt peut être $E(X)$. S'il suppose que ces variables possèdent une variance, le paramètre d'intérêt peut être $var(X)$.
- Si le modèle statistique suppose que X_1, \dots, X_n possèdent une densité f_X , le paramètre d'intérêt peut être $f_X(t)$ pour un $t \in \mathbb{R}$ donné.

Estimateur

Dans la suite, on note θ_0 la vraie valeur du paramètre d'intérêt et Θ l'ensemble des valeurs possibles pour θ_0 . Par exemple, $\Theta =]0, +\infty[$ si $\theta_0 = \text{var}(X)$ tandis que $\Theta = \mathbb{R}$ si $\theta_0 = E(X)$.

Définition : Un estimateur est une variable aléatoire souvent notée $\hat{\theta}_n$, à valeurs dans Θ , telle que pour une certaine fonction T_n , on a

$$\hat{\theta}_n(\omega) = T_n(X_1(\omega), \dots, X_n(\omega)) \text{ pour tout } \omega \in \Omega.$$

Remarques :

- ▷ Donner un **estimateur** $\hat{\theta}_n$ est donc équivalent à donner la fonction T_n .
- ▷ Un estimateur ne dépend du résultat ω de l'expérience aléatoire qu'au travers des réalisations de X_1, \dots, X_n , c'est-à-dire des données.
- ▷ Il existe toujours plusieurs (une infinité d') estimateurs de θ_0 .

Qualités d'un estimateur

Définitions : Soit $\hat{\theta}_n$ un estimateur de θ_0 .

- Le biais de $\hat{\theta}_n$ est le nombre $E(\hat{\theta}_n) - \theta_0$.
- On dit que $\hat{\theta}_n$ est **sans biais** si $E(\hat{\theta}_n) = \theta_0$.
- On dit que $\hat{\theta}_n$ est **asymptotiquement sans biais** si $\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = \theta_0$.
- On dit que $\hat{\theta}_n$ est **consistant** si $\hat{\theta}_n \xrightarrow[n \rightarrow \infty]{P} \theta_0$.
- Le **risque quadratique** de $\hat{\theta}_n$ est $E[(\hat{\theta}_n - \theta_0)^2]$.

Qualités requises :

On choisira toujours un estimateur sans biais ou asymptotiquement sans biais, consistant, et de risque quadratique le plus petit possible. Ainsi, entre deux estimateurs sans biais, on retiendra celui dont la variance est la plus petite.

Estimation

Définition : La réalisation d'un estimateur, $\hat{\theta}_n(\omega) = T_n(x_1, \dots, x_n)$, est appelée **estimation**.

Remarque :

L'estimation est la valeur que l'on va pouvoir calculer à partir des données. C'est elle qui fournit la valeur approchée de θ_0 .

Introduction

Méthode de substitution

Estimation non paramétrique : Estimation empirique

Estimation paramétrique : EMV

Méthode de substitution

Il découle du théorème de Slutsky que si l'on dispose d'un estimateur consistant $\hat{\theta}_n$ de θ_0 , alors pour toute fonction continue g , $g(\hat{\theta}_n)$ est un estimateur consistant de $g(\theta_0)$.

Par exemple, il découle de la LGN que $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ est un estimateur consistant de $E(X)$, donc $(\bar{X}_n)^2$ est un estimateur consistant de $(E(X))^2$.

Introduction

Méthode de substitution

Estimation non paramétrique : Estimation empirique

Estimation paramétrique : EMV

Estimation empirique

La méthode d'estimation empirique repose sur le fait que la loi empirique P_n fournit une bonne approximation de la vraie loi P_X lorsque n est grand.

Définition : L'estimateur empirique d'une caractéristique de P_X est la même caractéristique de P_n .

Exemples :

- Si $\theta_0 = E(X)$ alors l'estimateur empirique est l'espérance d'une variable aléatoire de loi P_n , c'est-à-dire $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$.
- Si le paramètre d'intérêt est $var(X)$ alors l'estimateur empirique est $\hat{\sigma}_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2$.
- L'estimateur empirique de $F_X(t)$ est $F_n(t)$ pour tout $t \in \mathbb{R}$.
- Pour toute fonction g telle que cela a un sens, l'estimateur empirique de $E(g(X))$ est $\frac{1}{n} \sum_{i=1}^n g(X_i)$.
- Il n'existe pas d'estimateur empirique de la densité de X .

Propriétés des estimateurs empiriques

On peut utiliser la méthode d'estimation empirique dans un modèle non paramétrique mais aussi dans un modèle paramétrique. Cette méthode fournit le plus souvent des estimateurs consistants et asymptotiquement sans biais (voire sans biais).

Exemples :

- $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ est un estimateur sans biais et consistant (LGN) de $E(X)$.
- $\hat{\sigma}_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2$ est un estimateur asymptotiquement sans biais et consistant (exercice) de $\text{var}(X)$. Un estimateur sans biais et consistant est l'estimateur empirique corrigé

$$S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2.$$

- $F_n(t)$ et $\frac{1}{n} \sum_{i=1}^n g(X_i)$ sont des estimateurs sans biais et consistants de $F_X(t)$ et $E(g(X))$, respectivement.

Introduction

Méthode de substitution

Estimation non paramétrique : Estimation empirique

Estimation paramétrique : EMV

Cadre

Dans la suite, on suppose qu'on dispose d'une famille de lois indexée par θ , $\{P_\theta, \theta \in \Theta\}$ avec $\Theta \subset \mathbb{R}^p$ donné, à laquelle appartient la loi de X : il existe donc θ_0 tel que $P_X = P_{\theta_0}$. On suppose dans la suite θ_0 identifiable au sens où $P_\theta \neq P_{\theta_0}$ dès lors que $\theta \neq \theta_0$. Connaître P_X revient alors à connaître θ_0 . On étudiera simultanément les deux cadres suivants :

- 1 La loi de X est discrète et on note $f_\theta(x) = P_\theta(\{x\})$ la probabilité de $\{X = x\}$ si $\theta_0 = \theta$, pour tout $x \in \Omega_X$.
- 2 Chaque P_θ possède une densité notée f_θ .

Vraisemblance

Définitions :

- La **vraisemblance** est la fonction (aléatoire) $L_n : \Theta \rightarrow [0, +\infty[$ telle que pour tout $\theta \in \Theta$,

$$L_n(\theta) = f_\theta(X_1) \times \cdots \times f_\theta(X_n).$$

- Si $f_\theta(x) > 0$ pour tout $x \in \Omega_X$ et tout $\theta \in \Theta$, alors la **log-vraisemblance** est la fonction (aléatoire) $\ell_n : \Theta \rightarrow \mathbb{R}$ telle que pour tout $\theta \in \Theta$,

$$\ell_n(\theta) = \log(L_n(\theta)) = \log(f_\theta(X_1)) + \cdots + \log(f_\theta(X_n)).$$

Exemple 1

Supposons que X_1, \dots, X_n sont i.i.d. $\mathcal{B}(p_0)$ avec $p_0 \in]0, 1[$. Avec les notations de la diapositive 14, $\theta_0 = p_0$, $\Theta =]0, 1[$ et pour tout $p \in \Theta$, P_p est la loi $\mathcal{B}(p)$. Pour tout $p \in]0, 1[$, on a

$$f_p(x) = p^x(1-p)^{1-x} \text{ pour tout } x \in \{0, 1\},$$

donc

$$\log(f_p(X_i)) = X_i \log(p) + (1 - X_i) \log(1 - p).$$

On en déduit que pour tout $p \in]0, 1[$, on a

$$\ell_n(p) = \sum_{i=1}^n \log(f_p(X_i)) = S_n \log p + (n - S_n) \log(1 - p)$$

où $S_n = X_1 + \dots + X_n$.

Exemple 1

Supposons que X_1, \dots, X_n sont i.i.d. $\mathcal{B}(p_0)$ avec $p_0 \in]0, 1[$. Avec les notations de la diapositive 14, $\theta_0 = p_0$, $\Theta =]0, 1[$ et pour tout $p \in \Theta$, P_p est la loi $\mathcal{B}(p)$. Pour tout $p \in]0, 1[$, on a

$$f_p(x) = p^x(1-p)^{1-x} \text{ pour tout } x \in \{0, 1\},$$

donc

$$\log(f_p(X_i)) = X_i \log(p) + (1 - X_i) \log(1 - p).$$

On en déduit que pour tout $p \in]0, 1[$, on a

$$\ell_n(p) = \sum_{i=1}^n \log(f_p(X_i)) = S_n \log p + (n - S_n) \log(1 - p)$$

où $S_n = X_1 + \dots + X_n$.

Exemple 1

Supposons que X_1, \dots, X_n sont i.i.d. $\mathcal{B}(p_0)$ avec $p_0 \in]0, 1[$. Avec les notations de la diapositive 14, $\theta_0 = p_0$, $\Theta =]0, 1[$ et pour tout $p \in \Theta$, P_p est la loi $\mathcal{B}(p)$. Pour tout $p \in]0, 1[$, on a

$$f_p(x) = p^x(1-p)^{1-x} \text{ pour tout } x \in \{0, 1\},$$

donc

$$\log(f_p(X_i)) = X_i \log(p) + (1 - X_i) \log(1 - p).$$

On en déduit que pour tout $p \in]0, 1[$, on a

$$\ell_n(p) = \sum_{i=1}^n \log(f_p(X_i)) = S_n \log p + (n - S_n) \log(1 - p)$$

où $S_n = X_1 + \dots + X_n$.

Exemple 2

Supposons que X_1, \dots, X_n sont i.i.d. $\mathcal{E}(\theta_0)$ avec $\theta_0 > 0$.

Pour tout $\theta > 0$ on a

$$f_\theta(x) = \theta \exp(-\theta x) \mathbb{1}_{\{x>0\}}.$$

De plus,

$$P(X_i \leq 0) = \int_{-\infty}^0 f_{\theta_0}(x) dx = 0$$

donc $X_i > 0$ p.s. On a donc $f_\theta(X_i) = \theta \exp(-\theta X_i)$ p.s. et

$$\log(f_\theta(X_i)) = \log \theta - \theta X_i \text{ p.s.}$$

Donc,

$$\ell_n(\theta) = \sum_{i=1}^n \log(f_\theta(X_i)) = n \log \theta - \theta S_n \text{ p.s. pour tout } \theta > 0$$

où $S_n = X_1 + \dots + X_n$.

Exemple 2

Supposons que X_1, \dots, X_n sont i.i.d. $\mathcal{E}(\theta_0)$ avec $\theta_0 > 0$.

Pour tout $\theta > 0$ on a

$$f_\theta(x) = \theta \exp(-\theta x) \mathbb{1}_{\{x>0\}}.$$

De plus,

$$P(X_i \leq 0) = \int_{-\infty}^0 f_{\theta_0}(x) dx = 0$$

donc $X_i > 0$ p.s. On a donc $f_\theta(X_i) = \theta \exp(-\theta X_i)$ p.s. et

$$\log(f_\theta(X_i)) = \log \theta - \theta X_i \text{ p.s.}$$

Donc,

$$\ell_n(\theta) = \sum_{i=1}^n \log(f_\theta(X_i)) = n \log \theta - \theta S_n \text{ p.s. pour tout } \theta > 0$$

où $S_n = X_1 + \dots + X_n$.

Exemple 2

Supposons que X_1, \dots, X_n sont i.i.d. $\mathcal{E}(\theta_0)$ avec $\theta_0 > 0$.

Pour tout $\theta > 0$ on a

$$f_\theta(x) = \theta \exp(-\theta x) \mathbb{1}_{\{x>0\}}.$$

De plus,

$$P(X_i \leq 0) = \int_{-\infty}^0 f_{\theta_0}(x) dx = 0$$

donc $X_i > 0$ p.s. On a donc $f_\theta(X_i) = \theta \exp(-\theta X_i)$ p.s. et

$$\log(f_\theta(X_i)) = \log \theta - \theta X_i \text{ p.s.}$$

Donc,

$$\ell_n(\theta) = \sum_{i=1}^n \log(f_\theta(X_i)) = n \log \theta - \theta S_n \text{ p.s. pour tout } \theta > 0$$

où $S_n = X_1 + \dots + X_n$.

Exemple 2

Supposons que X_1, \dots, X_n sont i.i.d. $\mathcal{E}(\theta_0)$ avec $\theta_0 > 0$.

Pour tout $\theta > 0$ on a

$$f_\theta(x) = \theta \exp(-\theta x) \mathbb{1}_{\{x > 0\}}.$$

De plus,

$$P(X_i \leq 0) = \int_{-\infty}^0 f_{\theta_0}(x) dx = 0$$

donc $X_i > 0$ p.s. On a donc $f_\theta(X_i) = \theta \exp(-\theta X_i)$ p.s. et

$$\log(f_\theta(X_i)) = \log \theta - \theta X_i \text{ p.s.}$$

Donc,

$$\ell_n(\theta) = \sum_{i=1}^n \log(f_\theta(X_i)) = n \log \theta - \theta S_n \text{ p.s. pour tout } \theta > 0$$

où $S_n = X_1 + \dots + X_n$.

Estimateur du maximum de vraisemblance (EMV)

Définition : On appelle **estimateur du maximum de vraisemblance** toute solution $\hat{\theta}_n$, si elle existe, de l'équation

$$L_n(\hat{\theta}_n) = \sup_{\theta \in \Theta} L_n(\theta).$$

Si $f_\theta(x) > 0$ pour tout $x \in \Omega_X$ et tout $\theta \in \Theta$, alors de façon équivalente, $\hat{\theta}_n$ est solution, si elle existe, de l'équation

$$\ell_n(\hat{\theta}_n) = \sup_{\theta \in \Theta} \ell_n(\theta).$$

Cela vient du fait que la fonction log est strictement croissante et continue. L'intérêt de cette écriture est qu'elle fait intervenir la log-vraisemblance, qui étant définie comme une somme de fonctions, est plus facile à dériver que la vraisemblance L_n .

Exemple 1

Supposons que X_1, \dots, X_n sont i.i.d. $\mathcal{B}(p_0)$ avec $p_0 \in]0, 1[$. Rappelons qu'alors,

$$\ell_n(p) = S_n \log p + (n - S_n) \log(1 - p)$$

pour tout $p \in]0, 1[$ où $S_n = X_1 + \dots + X_n$. Pour déterminer le lieu de maximum de la fonction ℓ_n , on la dérive :

$$\ell'_n(p) = \frac{S_n}{p} - \frac{n - S_n}{1 - p} = \frac{S_n(1 - p) - p(n - S_n)}{p(1 - p)} = \frac{S_n - np}{p(1 - p)}$$

On en déduit le tableau de signes :

p	0	S_n/n	1
ℓ'_n		+	-
ℓ_n		↗	↘

Donc l'EMV de p_0 est S_n/n .

Exemple 1

Supposons que X_1, \dots, X_n sont i.i.d. $\mathcal{B}(p_0)$ avec $p_0 \in]0, 1[$. Rappelons qu'alors,

$$\ell_n(p) = S_n \log p + (n - S_n) \log(1 - p)$$

pour tout $p \in]0, 1[$ où $S_n = X_1 + \dots + X_n$. Pour déterminer le lieu de maximum de la fonction ℓ_n , on la dérive :

$$\ell'_n(p) = \frac{S_n}{p} - \frac{n - S_n}{1 - p} = \frac{S_n(1 - p) - p(n - S_n)}{p(1 - p)} = \frac{S_n - np}{p(1 - p)}$$

On en déduit le tableau de signes :

p	0	S_n/n	1
ℓ'_n		+	-
ℓ_n		↗	↘

Donc l'EMV de p_0 est S_n/n .

Exemple 1

Supposons que X_1, \dots, X_n sont i.i.d. $\mathcal{B}(p_0)$ avec $p_0 \in]0, 1[$.
Rappelons qu'alors,

$$\ell_n(p) = S_n \log p + (n - S_n) \log(1 - p)$$

pour tout $p \in]0, 1[$ où $S_n = X_1 + \dots + X_n$. Pour déterminer le lieu de maximum de la fonction ℓ_n , on la dérive :

$$\ell'_n(p) = \frac{S_n}{p} - \frac{n - S_n}{1 - p} = \frac{S_n(1 - p) - p(n - S_n)}{p(1 - p)} = \frac{S_n - np}{p(1 - p)}$$

On en déduit le tableau de signes :

p	0	S_n/n	1
ℓ'_n		+	-
ℓ_n		↗	↘

Donc l'EMV de p_0 est S_n/n .

Exemple 2

Supposons que X_1, \dots, X_n sont i.i.d. $\mathcal{E}(\theta_0)$ avec $\theta_0 > 0$. Rappelons qu'alors,

$$\ell_n(\theta) = n \log \theta - \theta S_n \text{ p.s.}$$

pour tout $\theta > 0$ où $S_n = X_1 + \dots + X_n$. Pour déterminer le lieu de maximum de la fonction ℓ_n , on la dérive :

$$\ell'_n(\theta) = \frac{n}{\theta} - S_n$$

On en déduit le tableau de signes :

θ	0	n/S_n	$+\infty$
ℓ'_n	+	0	-
ℓ_n	\nearrow		\searrow

Donc l'EMV de θ_0 est n/S_n c'est-à-dire $1/\bar{X}_n$, où $\bar{X}_n = \sum_{i=1}^n X_i/n$.

Exemple 2

Supposons que X_1, \dots, X_n sont i.i.d. $\mathcal{E}(\theta_0)$ avec $\theta_0 > 0$. Rappelons qu'alors,

$$\ell_n(\theta) = n \log \theta - \theta S_n \text{ p.s.}$$

pour tout $\theta > 0$ où $S_n = X_1 + \dots + X_n$. Pour déterminer le lieu de maximum de la fonction ℓ_n , on la dérive :

$$\ell'_n(\theta) = \frac{n}{\theta} - S_n$$

On en déduit le tableau de signes :

θ	0	n/S_n	$+\infty$
ℓ'_n	+	0	-
ℓ_n	\nearrow		\searrow

Donc l'EMV de θ_0 est n/S_n c'est-à-dire $1/\bar{X}_n$, où $\bar{X}_n = \sum_{i=1}^n X_i/n$.

Exemple 2

Supposons que X_1, \dots, X_n sont i.i.d. $\mathcal{E}(\theta_0)$ avec $\theta_0 > 0$. Rappelons qu'alors,

$$\ell_n(\theta) = n \log \theta - \theta S_n \text{ p.s.}$$

pour tout $\theta > 0$ où $S_n = X_1 + \dots + X_n$. Pour déterminer le lieu de maximum de la fonction ℓ_n , on la dérive :

$$\ell'_n(\theta) = \frac{n}{\theta} - S_n$$

On en déduit le tableau de signes :

θ	0	n/S_n	$+\infty$
ℓ'_n	+	0	-
ℓ_n	\nearrow		\searrow

Donc l'EMV de θ_0 est n/S_n c'est-à-dire $1/\bar{X}_n$, où $\bar{X}_n = \sum_{i=1}^n X_i/n$.

Remarques

- L'EMV n'existe pas toujours. S'il existe, il n'est pas nécessairement unique, et pas nécessairement explicite.
- Dans le cas d'un paramètre réel $\Theta \subset \mathbb{R}$, si $f_\theta(x) > 0$ pour tout $x \in \Omega_X$ et tout $\theta \in \Theta$, et si $\theta \mapsto f_\theta(x)$ est dérivable pour tout x , alors pour calculer l'EMV :
 - ▷ on calcule L_n puis ℓ_n
 - ▷ on calcule la dérivée de ℓ_n
 - ▷ on dresse le tableau de variations de ℓ_n
 - ▷ on en déduit la valeur de l'EMV (le point, s'il existe), où cette fonction est maximale.

Familles exponentielles

Définition : Dans le cas d'un paramètre réel avec Θ un intervalle ouvert de \mathbb{R} , on dit que la famille de lois $\{P_\theta, \theta \in \Theta\}$ est exponentielle si f_θ peut s'écrire sous la forme

$$f_\theta(x) = h(x)C(\theta) \exp(G(\theta)T(x))$$

pour tout $\theta \in \Theta$ et tout $x \in \Omega_X$, pour certaines fonctions h, C, G, T avec G indéfiniment dérivable telle que $G'(\theta) > 0$ pour tout θ .

Exemples : Les familles de lois suivantes sont exponentielles :

- $\{\mathcal{B}(\theta), \theta \in]0, 1[\}$
- $\{\mathcal{E}(\theta), \theta > 0\}$
- $\{\mathcal{P}(\theta), \theta > 0\}$
- $\{\mathcal{N}(m, \sigma^2), m \in \mathbb{R}\}$, avec $\sigma > 0$ donné

Exemple 1

$$\begin{aligned}
 f_p(x) &= p^x(1-p)^{1-x} \\
 &= (1-p) \left(\frac{p}{1-p} \right)^x \\
 &= (1-p) \exp \left(x \log \left(\frac{p}{1-p} \right) \right)
 \end{aligned}$$

Donc

$$f_p(x) = h(x)C(p) \exp(G(p)T(x))$$

si on pose (par exemple) $h(x) = 1$, $C(p) = 1 - p$, $T(x) = x$,
 $G(p) = \log(p/(1 - p))$.

Exemple 2

$$\begin{aligned}f_{\theta}(x) &= \theta \exp(-\theta x) \mathbb{1}_{\{x>0\}} \\ &= h(x) C(\theta) \exp(G(\theta) T(x))\end{aligned}$$

si on pose (par exemple) $h(x) = \mathbb{1}_{\{x>0\}}$, $C(\theta) = \theta$, $T(x) = -x$,
 $G(\theta) = \theta$.

Définitions : Si $\{P_\theta, \theta \in \Theta\}$ est une famille exponentielle de lois, alors

- Le **score** est $\dot{\ell}_{\theta_0}(X) = \frac{\partial}{\partial \theta_0} \log f_{\theta_0}(X)$
- L'**information de Fisher** est $I(\theta_0) = E[(\dot{\ell}_{\theta_0}(X))^2]$.

Exemple 1

On rappelle (voir la diapositive 16) que

$$\log(f_p(X)) = X \log(p) + (1 - X) \log(1 - p).$$

donc le score est

$$\begin{aligned} \frac{\partial}{\partial p_0} \log f_{p_0}(X) &= \frac{X}{p_0} - \frac{1 - X}{1 - p_0} \\ &= \frac{X - p_0}{p_0(1 - p_0)} \end{aligned}$$

et l'information de Fisher est

$$\begin{aligned} I(\theta_0) &= \frac{E[(X - p_0)^2]}{(p_0(1 - p_0))^2} \\ &= \frac{\text{var}(X)}{(p_0(1 - p_0))^2} \\ &= \frac{1}{p_0(1 - p_0)} \end{aligned}$$

Théorème : Si $\{P_\theta, \theta \in \Theta\}$ est une famille exponentielle de lois, alors

- $E(\dot{\ell}_{\theta_0}(X)) = 0$ et $I(\theta_0) = \text{var}(\dot{\ell}_{\theta_0}(X))$.
- $I(\theta_0) = -E[\frac{\partial^2}{\partial^2\theta_0} \log f_{\theta_0}(X)]$.
- Si l'EMV $\hat{\theta}_n$ de θ_0 existe et $I(\theta_0) > 0$, alors

$$\sqrt{nl(\theta_0)}(\hat{\theta}_n - \theta_0) \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 1).$$

- Si l'EMV $\hat{\theta}_n$ de θ_0 existe, $I(\theta_0) > 0$, et $\theta \mapsto I(\theta)$ est une fonction continue, alors $\sqrt{nl(\hat{\theta}_n)}(\hat{\theta}_n - \theta_0) \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 1)$.

Par exemple, si X_1, \dots, X_n sont i.i.d. $\mathcal{B}(\theta_0)$ pour un $\theta_0 \in]0, 1[$, alors

$$\sqrt{n} \frac{\bar{X}_n - \theta_0}{\sqrt{\bar{X}_n(1 - \bar{X}_n)}} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 1).$$

Remarque : Sous les hypothèses précédentes, l'EMV est consistant.

Théorème (Borne de Cramer-Rao) : Si $\{P_\theta, \theta \in \Theta\}$ est une famille exponentielle de lois, alors tout estimateur sans biais $\hat{\theta}_n$ de θ_0 vérifie

$$\text{var}(\hat{\theta}_n) \geq \frac{1}{nI(\theta_0)}.$$

Définition : Dans le cadre des familles exponentielles, un estimateur sans biais $\hat{\theta}_n$ est dit efficace si

$$\text{var}(\hat{\theta}_n) = \frac{1}{nI(\theta_0)}.$$

Exemple 1 : L'EMV est efficace dans le modèle de Bernoulli, puisque l'EMV est \bar{X}_n , de variance $p_0(1 - p_0)/n = 1/(nI(p_0))$.