

# Statistique Mathématique

Salim Lardjane

*Université Bretagne Sud*

Partie IV  
*Estimateurs Uniformément Sans Biais de  
Variance Minimale*

## Statistiques exhaustives

---

Soit  $X_1, \dots, X_n$  un échantillon i.i.d associée à une v.a.  $X$  de loi  $\mathcal{B}(\theta)$ , c'est-à-dire que :

$$\mathbb{P}(X_i = x) = \theta^x (1 - \theta)^{1-x} \quad (x = 0, 1).$$

Soit  $Y$  une *statistique*, c'est-à-dire une variable aléatoire fonction des observations  $X_1, \dots, X_n$ .

Plus précisément, soit :

$$Y = X_1 + \dots + X_n.$$

$Y$  est le nombre de succès observés sur  $n$  essais de Bernoulli, la probabilité de succès d'un essai étant  $\theta$ .

## Statistiques exhaustives

---

*Théorème.* La loi conditionnelle de  $X_1, \dots, X_n$  sachant  $Y$  ne dépend pas de  $\theta$ .

On dit que la statistique  $Y$  est *exhaustive* pour  $\theta$ .

*Preuve.* Par définition, nous avons :

$$\begin{aligned} & \mathbb{P}(X_1 = x_1, \dots, X_n = x_n | Y = y) \\ &= \frac{\mathbb{P}_\theta(X_1 = x_1, \dots, X_n = x_n, Y = y)}{\mathbb{P}_\theta(Y = y)}. \end{aligned}$$

Or la probabilité au numérateur vaut 0 à moins que l'on ait  $y = x_1 + \dots + x_n$ , auquel cas :

$$\mathbb{P}(X_1 = x_1, \dots, X_n = x_n | Y = y) = \frac{\theta^y (1 - \theta)^{n-y}}{C_n^y \theta^y (1 - \theta)^{n-y}} = \frac{1}{C_n^y}.$$

## **Statistiques exhaustives**

---

Par exemple, si l'on sait qu'on obtient 3 succès en 5 lancers, la probabilité que le résultat soit *SESSE* est  $1/C_5^3 = 1/10$ , où on note *S* pour succès et *E* pour échec.

## Statistiques exhaustives

---

Une conséquence du résultat précédent est que *pour prendre une décision statistique*, on peut se baser *uniquement sur*  $X_1 + \dots + X_n$  et ignorer le détail des observations.

En effet, supposons que le statisticien A observe  $X_1, \dots, X_n$  et qu'il prenne une décision sur cette base, par exemple qu'il estime  $\theta$  par  $T(X_1, \dots, X_n)$ .

Supposons également que la statisticienne B observe uniquement  $X_1 + \dots + X_n$  et tire  $X'_1, \dots, X'_n$  selon la loi conditionnelle de  $X_1, \dots, X_n$  sachant  $Y$ , c'est-à-dire que :

$$\mathbb{P}(X'_1 = x_1, \dots, X'_n = x_n | Y = y) = \frac{1}{C_n^y}.$$

Ce tirage est possible car la loi conditionnelle *ne dépend pas du paramètre inconnu*  $\theta$ .

Nous avons alors le résultat suivant.

## Statistiques exhaustives

---

*Théorème.*  $(X'_1, \dots, X'_n)$  et  $(X_1, \dots, X_n)$  sont de même loi.

*Preuve.* Etant données les valeurs  $x_1, \dots, x_n$ , soit  $y = x_1 + \dots + x_n$ . Si

$$X'_1 = x_1, \dots, X'_n = x_n$$

alors  $Y = X_1 + \dots + X_n = y$  et le tirage effectué par B produit  $X'_1 = x_1, \dots, X'_n = x_n$  avec la probabilité :

$$\begin{aligned} \mathbb{P}_\theta(X'_1 = x_1, \dots, X'_n = x_n) &= \mathbb{P}_\theta(Y = y) \cdot \\ &\quad \cdot \mathbb{P}_\theta(X'_1 = x_1, \dots, X'_n = x_n | Y = y) \\ &= C_n^y \theta^y (1 - \theta)^{n-y} \frac{1}{C_n^y} \\ &= \mathbb{P}_\theta(X_1 = x_1, \dots, X_n = x_n). \end{aligned}$$

Par conséquent, les estimateurs  $T(X_1, \dots, X_n)$  et  $T(X'_1, \dots, X'_n)$  sont de même loi. On peut donc estimer indifféremment  $\theta$  à l'aide de l'un ou l'autre, avec les mêmes propriétés.

## Théorème de Factorisation

Soit  $X$  une variable ou un vecteur aléatoire de densité  $f_\theta(x)$  et soit  $Y = u(X)$  une statistique.

Le plus souvent  $X = (X_1, \dots, X_n)$ , un échantillon i.i.d. d'observations, et  $Y$  est un *estimateur* de  $\theta$ .

*Théorème (de factorisation).*  $Y = u(X)$  est une statistique exhaustive pour  $\theta$  si et seulement si la densité de  $X$  peut être factorisée sous la forme :

$$f_\theta(x) = g(\theta, u(x))h(x).$$

Dans le cas d'un échantillon de Bernoulli, vu précédemment, on a :

$$f_\theta(x_1, \dots, x_n) = \theta^y (1 - \theta)^{n-y}$$

$$u(x) = y = \sum_{i=1}^n x_i$$

$$h(x) \equiv 1.$$



## Théorème de Factorisation

*Preuve du théorème.* On donne la preuve dans le cas discret uniquement.

Si  $Y = u(X)$  est une statistique exhaustive pour  $\theta$ , alors :

$$\begin{aligned}\mathbb{P}_\theta(X = x) &= \mathbb{P}_\theta(X = x, Y = u(x)) \\ &= \mathbb{P}_\theta(Y = u(x))\mathbb{P}(X = x|Y = u(x)) \\ &= g(\theta, u(x))h(x).\end{aligned}$$

Réciproquement, si  $f_\theta(x) = g(\theta, u(x))h(x)$ , alors :

$$\mathbb{P}_\theta(X = x|Y = y) = \frac{\mathbb{P}_\theta(X = x, Y = y)}{\mathbb{P}_\theta(Y = y)}$$

et le numérateur vaut 0 sauf si  $y = u(x)$ , auquel cas l'expression précédente devient :

$$\frac{\mathbb{P}_\theta(X = x)}{\mathbb{P}_\theta(Y = y)} = \frac{g(\theta, u(x))h(x)}{\sum_{z:u(z)=y} g(\theta, u(z))h(z)}.$$

## **Théorème de Factorisation**

Les termes en  $g$  au numérateur et au dénominateur sont égaux à  $g(\theta, y)$  et peuvent donc être éliminés.

Ainsi, on obtient :

$$\mathbb{P}_\theta(X = x|Y = y) = \frac{h(x)}{\sum_{z:u(z)=y} h(z)},$$

expression qui ne dépend pas de  $\theta$ , d'où l'exhaustivité de  $Y$  pour  $\theta$ .

## Exemple

---

Soit  $X_1, \dots, X_n$  un échantillon i.i.d. associé à une v.a.r.  $X$  de loi  $\mathcal{N}(\mu, \sigma^2)$ .

On a donc :

$$\begin{aligned} f_{\theta}(x_1, \dots, x_n) &= \prod_{i=1}^n \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x_i - \mu)^2}{2\sigma^2}\right) \\ &= \left(\frac{1}{\sigma\sqrt{2\pi}}\right)^n \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right] \end{aligned}$$

Posons  $\theta = (\mu, \sigma^2)$  et soient

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

et

$$s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2.$$

## Exemple

---

Alors, on peut écrire :

$$x_i - \bar{x} = x_i - \mu - (\bar{x} - \mu)$$

et

$$s^2 = \frac{1}{n} \left[ \sum_{i=1}^n (x_i - \mu)^2 - 2(\bar{x} - \mu) \sum_{i=1}^n (x_i - \mu) + n(\bar{x} - \mu)^2 \right].$$

Or  $\sum_{i=1}^n (x_i - \mu) = n(\bar{x} - \mu)$ , d'où

$$s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 - (\bar{x} - \mu)^2$$

et la densité conjointe s'écrit :

$$f_{\theta}(x_1, \dots, x_n) = (2\pi\sigma^2)^{-n/2} e^{-ns^2/2\sigma^2} e^{-n(\bar{x}-\mu)^2/2\sigma^2}$$

## Exemple

---

Si  $\mu$  et  $\sigma^2$  sont toutes deux inconnues, alors  $\theta = (\mu, \sigma^2)$  et  $(\bar{X}, S^2)$  est exhaustive pour  $\theta$ , avec :

$$h(x) \equiv 1.$$

Si  $\sigma^2$  est connue et  $\mu$  inconnue,  $\theta = \mu$  et  $\bar{X}$  est exhaustive pour  $\theta$ . C'est une conséquence du théorème de factorisation avec

$$h(x) = (2\pi\sigma^2)^{-n/2} e^{-ns^2/2\sigma^2}.$$

Si  $\mu$  est connue et  $\sigma^2$  est inconnue, alors  $\theta = \sigma^2$  et  $\sum_{i=1}^n (X_i - \mu)^2$  est exhaustive pour  $\theta$ . C'est une conséquence du théorème de factorisation avec

$$h(x) \equiv 1$$

dans l'expression initiale de la densité conjointe.

## Théorème de Rao-Blackwell

Afin de mieux comprendre le cheminement conduisant au théorème de Rao-Blackwell, commençons par considérer une expérience en deux étapes :

Etape 1. On observe une v.a.r.  $X$  de densité  $\frac{1}{2}x^2e^{-x}$  ( $x > 0$ )

Etape 2. Si  $X = x$  on tire  $Y$  selon la loi uniforme sur  $]0, x[$ .

On souhaite déterminer  $\mathbb{E}(Y)$ .

## Théorème de Rao-Blackwell

*Méthode 1* (densité conjointe). Nous avons :

$$\begin{aligned} f(x, y) &= f_X(x) f_Y(y|x) \\ &= \frac{1}{2} x^2 e^{-x} \cdot \frac{1}{x} \\ &= \frac{1}{2} x e^{-x} \quad (0 < y < x) \end{aligned}$$

En toute généralité, on a :

$$\mathbb{E}[g(X, Y)] = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} g(x, y) f(x, y) dx dy.$$

Dans notre cas, on a  $g(x, y) = y$ , d'où :

$$\begin{aligned} \mathbb{E}(Y) &= \int_0^{\infty} \left( \int_0^x \frac{y}{2} dy \right) x e^{-x} dx \\ &= \int_0^{\infty} \frac{x^3}{4} e^{-x} dx = \frac{\Gamma(4)}{4} \\ &= \frac{3!}{4} = \frac{3}{2} \end{aligned}$$

## Théorème de Rao-Blackwell

*Méthode 2.* Cette méthode fonctionne bien lorsque l'espérance conditionnelle est facile à calculer. Dans notre cas :

$$\mathbb{E}(Y|X = x) = \frac{x}{2}$$

puisque  $Y|X = x \sim \mathcal{U}]0,x[$ .

Par conséquent :

$$\begin{aligned}\mathbb{E}(Y) &= \mathbb{E}[\mathbb{E}(Y|X)] \quad (\text{Lemme 1 ci-après}) \\ &= \mathbb{E}(X/2) \quad (\text{Remarque ci-après}) \\ &= \int_0^{\infty} \frac{x}{2} \cdot \frac{1}{2} x^2 e^{-x} dx \\ &= \frac{3}{2}.\end{aligned}$$



## Théorème de Rao-Blackwell

**Remarque.** Si on obtient, par exemple, que  $\mathbb{E}[Y|X = x] = x^2 + 3x + 4$ , alors on peut écrire

$$\mathbb{E}[Y|X] = X^2 + 3X + 4.$$

Ainsi,  $\mathbb{E}(Y|X)$  est une fonction  $g(X)$  de la v.a.  $X$ .

Lorsque  $X = x$ , on note  $g(x) = \mathbb{E}[Y|X = x]$ .

## Théorème de Rao-Blackwell

**Lemme 1.** Soient  $X_1, X_2$  deux variables aléatoires réelles, alors

$$\mathbb{E}[\mathbb{E}(X_2|X_1)] = \mathbb{E}(X_2).$$

*Preuve.* Soit  $g(X_1) = \mathbb{E}(X_2|X_1)$ . Alors, on a :

$$\begin{aligned}\mathbb{E}[g(X_1)] &= \int_{-\infty}^{+\infty} g(x_1) f_1(x_1) dx_1 \\ &= \int_{-\infty}^{+\infty} \mathbb{E}[X_2|X_1 = x_1] f_1(x_1) dx_1 \\ &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x_2 f_{2|1}(x_2|x_1) f_1(x_1) dx_1 dx_2 \\ &= \int_{-\infty}^{+\infty} x_2 \left( \int_{-\infty}^{+\infty} f(x_1, x_2) dx_1 \right) dx_2 \\ &= \int_{-\infty}^{+\infty} x_2 f_2(x_2) dx_2 \\ &= \mathbb{E}(X_2).\end{aligned}$$

.

## Théorème de Rao-Blackwell

**Lemme 2.** Soient  $X_1, X_2$  deux variables aléatoires réelles et supposons  $\mu_1 = \mathbb{E}(X_1)$  et  $\mu_2 = \mathbb{E}(X_2)$  bien définies, alors :

$$\mathbb{E} [(X_2 - \mathbb{E}(X_2|X_1))(\mathbb{E}[X_2|X_1] - \mu_2)] = 0.$$

*Preuve.* L'espérance s'écrit :

$$\begin{aligned} & \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} [x_2 - \mathbb{E}(X_2|X_1 = x_1)] \cdot [\mathbb{E}(X_2|X_1 = x_1) - \mu_2] \\ & \qquad \qquad \qquad \cdot f_1(x_1) f_{2|1}(x_2|x_1) dx_1 dx_2 \\ & = \int_{-\infty}^{+\infty} f_1(x_1) [\mathbb{E}(X_2|X_1 = x_1) - \mu_2] \cdot \\ & \qquad \cdot \left( \int_{-\infty}^{+\infty} [x_2 - \mathbb{E}(X_2|X_1 = x_1)] f_{2|1}(x_2|x_1) dx_2 \right) dx_1 \end{aligned}$$

Or l'intégrale entre parenthèse vaut :

$$\mathbb{E}(X_2|X_1 = x_1) - \mathbb{E}(X_2|X_1 = x_1) = 0,$$

d'où le résultat.

## Théorème de Rao-Blackwell

**Lemme 3.** Soient  $X_1, X_2$  deux variables aléatoires réelles, de variances bien définies, alors :

$$V(X_2) \geq V(\mathbb{E}[X_2|X_1]).$$

*Preuve.* Nous pouvons écrire :

$$\begin{aligned} V(X_2) &= \mathbb{E}[(X_2 - \mu_2)^2] \\ &= \mathbb{E}[(X_2 - \mathbb{E}(X_2|X_1)) \\ &\quad + (\mathbb{E}(X_2|X_1) - \mu_2)]^2) \\ &= \mathbb{E}[(X_2 - \mathbb{E}(X_2|X_1))^2] \\ &\quad + \mathbb{E}[(\mathbb{E}(X_2|X_1) - \mu_2)^2] \quad (\text{Lemme 2}) \\ &\geq \mathbb{E}[(\mathbb{E}(X_2|X_1) - \mu_2)^2] \end{aligned}$$

car les deux termes sont positifs.

Mais en vertu du Lemme 1, on a

$$\mathbb{E}[\mathbb{E}(X_2|X_1)] = \mu_2$$

Ainsi,

$$\mathbb{E}[(\mathbb{E}(X_2|X_1) - \mu_2)^2] = V(\mathbb{E}[X_2|X_1])$$

d'où le résultat.

## Théorème de Rao-Blackwell

**Lemme 4.** Soient  $X_1, X_2$  deux variables aléatoires réelles, de variances bien définies, alors  $V(X_2) = V(\mathbb{E}[X_2|X_1])$  si et seulement si  $X_2$  est une fonction de  $X_1$ .

*Preuve.* La preuve du Lemme 3 montre qu'il y a égalité si et seulement si :

$$\mathbb{E}[(X_2 - \mathbb{E}(X_2|X_1))^2] = 0,$$

c'est-à-dire si et seulement si  $X_2 = \mathbb{E}(X_2|X_1)$  (voir Remarque à suivre). Ceci implique que  $X_2$  est une fonction de  $X_1$ .

Réciproquement, si  $X_2 = h(X_1)$ , alors  $\mathbb{E}(X_2|X_1) = h(X_1) = X_2$ , d'où l'égalité des variances.

## Théorème de Rao-Blackwell

**Remarque.** On a utilisé le résultat suivant dans la preuve précédente : *Soit  $X$  une v.a.r. telle que  $\mathbb{E}(X^2) = 0$ . Alors,  $X = 0$ .*

En toute rigueur, l'égalité est *presque sure*, mais on ne détaillera pas cet aspect dans ce cours.

## Théorème de Rao-Blackwell

**Théorème de Rao-Blackwell.** Soit  $X_1, \dots, X_n$  un échantillon i.i.d. associé à une v.a.r.  $X$  de densité  $f_\theta(x)$ . Soit  $Y_1 = u_1(X_1, \dots, X_n)$  une statistique exhaustive pour  $\theta$  et soit  $Y_2 = u_2(X_1, \dots, X_n)$  un estimateur sans biais de  $r(\theta)$ , où  $r$  est une fonction quelconque de  $\theta$ . Alors,

1.  $V(\mathbb{E}[Y_2|Y_1]) \leq V(Y_2)$ , l'inégalité étant stricte sauf si  $Y_2$  est une fonction de  $Y_1$ .
2.  $\mathbb{E}[\mathbb{E}(Y_2|Y_1)] = r(\theta)$ .

## **Théorème de Rao-Blackwell**

*Ainsi, lorsqu'on cherche un estimateur sans biais de variance minimale de  $r(\theta)$ , on peut se limiter aux seules fonctions de la statistique exhaustive  $Y_1$ .*

*Preuve.* La propriété 1. est une conséquence des Lemmes 3 et 4. La propriété 2. découle du Lemme 1.



## Exhaustivité et EMV

---

Soit  $Y_1 = u_1(X_1, \dots, X_n)$  une statistique exhaustive pour  $\theta$ .

**Théorème.** *Si l'estimateur du maximum de vraisemblance  $\hat{\theta}_n$  de  $\theta$  est unique, alors  $\hat{\theta}_n$  est fonction de  $Y_1$ .*

*Preuve.* La densité conjointe des  $X_i$  peut être factorisée sous la forme :

$$f_{\theta}(x_1, \dots, x_n) = g(\theta, z)h(x_1, \dots, x_n)$$

où  $z = u_1(x_1, \dots, x_n)$ . Soit  $\theta_0$  la valeur possible de  $\theta$  qui maximise  $g(\theta, z)$ . Etant donné  $z$ , on peut déterminer  $\theta_0$  en examinant tous les  $g(\theta, z)$  ; ainsi,  $\theta_0$  est fonction de  $u_1(x_1, \dots, x_n) = y_1$ . Mais  $\theta_0$  maximise également  $f_{\theta}(x_1, \dots, x_n)$ , d'où  $\hat{\theta} = \theta_0$  par unicité, où  $\hat{\theta}$  désigne l'estimation par maximum de vraisemblance de  $\theta$ . On en déduit que l'EMV  $\hat{\theta}_n$  est fonction de  $Y_1$ .

## **Estimateurs USBVM**

---

Les résultats précédents nous permettront de trouver des estimateurs USBVM (uniformément sans biais de variance minimale) de  $\theta$ , ainsi que nous le verrons dans la suite.

## Estimateurs USBVM

---

Soit  $Y$  une statistique exhaustive pour  $\theta$ .

On dit que  $Y$  est *complète* s'il n'existe pas d'estimateur non trivial de 0 basé sur  $Y$ , c'est-à-dire si :

$$\mathbb{E}_\theta[g(Y)] = 0 \forall \theta \implies \mathbb{P}_\theta[g(Y) = 0] = 1 \forall \theta.$$

## **Estimateurs USBVM**

---

Si  $Y$  est une statistique exhaustive complète pour  $\theta$  et si on dispose de deux estimateurs sans biais de  $r(\theta)$  basés sur  $Y$ ,  $\varphi(Y)$  et  $\psi(Y)$ , alors comme :

$$\mathbb{E}_\theta[\varphi(Y) - \psi(Y)] = 0 \quad \forall \theta$$

on a nécessairement que

$$\mathbb{P}_\theta[\varphi(Y) = \psi(Y)] = 1 \quad \forall \theta.$$

Par conséquent, si on trouve un estimateur sans biais de  $r(\theta)$  basé sur  $Y$ , alors on les a essentiellement tous trouvés.

## Estimateurs USBVM

---

**Théorème de Lehmann-Scheffé.** Soit  $Y_1 = u_1(X_1, \dots, X_n)$  une statistique exhaustive complète pour  $\theta$ . Si  $\varphi(Y_1)$  est un estimateur sans biais de  $r(\theta)$  basé sur  $Y_1$ , alors parmi tous les estimateurs sans biais de  $r(\theta)$ ,  $\varphi(Y_1)$  est de variance minimale, c'est-à-dire que pour tout estimateur sans biais  $Y_2$  de  $r(\theta)$  :

$$V_\theta[\varphi(Y_1)] \leq V_\theta(Y_2) \quad \forall \theta.$$

On dit que  $\varphi(Y_1)$  est un *estimateur uniformément sans biais de variance minimale* (ang. Uniformly Minimum Variance Unbiased Estimator) ou estimateur USBVM (ang. UMVUE) de  $r(\theta)$ .

Le terme "uniformément" est utilisé car le résultat est vrai pour *toutes les valeurs possibles de  $\theta$* .

## Estimateurs USBVM

---

*Preuve.* En vertu du théorème de Rao-Blackwell, si  $Y_2$  est un estimateur sans biais quelconque de  $r(\theta)$ , alors  $\mathbb{E}(Y_2|Y_1)$  est un estimateur sans biais de  $r(\theta)$  avec

$$V[\mathbb{E}(Y_2|Y_1)] \leq V(Y_2).$$

Mais  $\mathbb{E}(Y_2|Y_1)$  est fonction de  $Y_1$ , donc il coïncide essentiellement avec  $\phi(Y_1)$  en vertu de la complétude de  $Y_1$  et a donc même variance.

Ainsi, indépendamment de la valeur de  $\theta$ , on a :

$$V_\theta[\phi(Y_1)] \leq V_\theta(Y_2).$$

## Estimateurs USBVM

---

Il existe de nombreux modèles pour lesquels on peut trouver facilement des statistiques exhaustives complètes.

C'est le cas notamment de *la famille exponentielle*.

Celle-ci regroupe les densités de la forme :

$$f_{\theta}(x) = a(\theta)b(x) \exp \left[ \sum_{j=1}^m p_j(\theta) K_j(x) \right]$$

où  $a(\theta) > 0$ ,  $b(x) > 0$ ,  $\alpha < x < \beta$ ,  $\theta = (\theta_1, \dots, \theta_k)$  avec  $\gamma_j < \theta_j < \delta_j$ ,  $1 \leq j \leq k$  ( $\alpha, \beta, \gamma_j, \delta_j$  sont des constantes).

## **Estimateurs USBVM**

---

Des *conditions de régularité* doivent en toute rigueur être imposées, mais elles seront toujours vérifiées dans les exemples que nous aurons à considérer, donc nous les omettons.

Dans tous les exemples considérés, on aura  $k = m$ . *C'est requis pour avoir la complétude.*



## Estimateurs USBVM

---

**Exemples.** Les modèles suivant appartiennent à la famille exponentielle (le démontrer à titre d'exercice) :

(a)  $\mathcal{B}(n, p)$ ,  $\theta = p$

(b)  $\mathcal{P}(\theta)$

(c)  $\mathcal{N}(\mu, \sigma^2)$ ,  $\theta = (\mu, \sigma^2)$

(d)  $\gamma(\alpha, \beta)$ ,  $\theta = (\alpha, \beta)$

(e)  $\beta(a, b)$ ,  $\theta = (a, b)$

## **Estimateurs USBVM**

---

*Nous allons à présent obtenir une statistique exhaustive complète pour les membres de la famille exponentielle.*

## Estimateurs USBVM

---

La densité des membres de la famille exponentielle s'écrit :

$$f_{\theta}(x) = a(\theta)b(x) \exp \left[ \sum_{j=1}^m p_j(\theta)K_j(x) \right].$$

La densité conjointe de  $n$  observations i.i.d. est donc donnée par :

$$f_{\theta}(x_1, \dots, x_n) = a(\theta)^n \prod_{i=1}^n b(x_i) \exp \left[ \sum_{j=1}^m p_j(\theta)K_j(x_1) \right] \\ \dots \exp \left[ \sum_{j=1}^m p_j(\theta)K_j(x_n) \right].$$

## Estimateurs USBVM

---

Mais, en vertu des propriétés de l'exponentielle, on a :

$$\begin{aligned} \exp \left[ \sum_{j=1}^m p_j(\theta) K_j(x_1) \right] \cdots \exp \left[ \sum_{j=1}^m p_j(\theta) K_j(x_n) \right] \\ = \exp \left[ \sum_{j=1}^m p_j(\theta) (K_j(x_1) + \cdots + K_j(x_n)) \right] \end{aligned}$$

Donc, en vertu du théorème de factorisation, avec  $h(x) = \prod_{i=1}^n b(x_i)$ , la statistique :

$$\left( \sum_{i=1}^n K_1(X_i), \dots, \sum_{i=1}^n K_m(X_i) \right)$$

est exhaustive pour  $\theta$ .

*On admettra que cette statistique est également complète.*

## Estimateurs USBVM

---

**Exemple.** Soit  $X_1, \dots, X_n$  un échantillon associé à une v.a.r.  $X$  de loi  $\mathcal{N}(\mu, \sigma^2)$ , où  $\sigma^2$  est connu.

Nous pouvons écrire :

$$\begin{aligned} f_{\mu}(x) &= \frac{1}{\sigma\sqrt{2\pi}} \exp\left[\frac{(x-\mu)^2}{2\sigma^2}\right] \\ &= \frac{1}{\sigma\sqrt{2\pi}} \exp\left[\frac{-\mu^2}{2\sigma^2}\right] \exp\left[-\frac{x^2}{2\sigma^2}\right] \exp\left[\frac{\mu x}{\sigma^2}\right] \\ &= a(\mu)b(x) \exp[p(\mu)K(x)] \end{aligned}$$

avec  $p(x) = \mu/\sigma^2$  et  $K(x) = x$ . Ainsi, notre modèle appartient à la famille exponentielle et, par conséquent,

$$\sum_{i=1}^n X_i$$

ou, de façon équivalente,  $\bar{X}$ , est exhaustive et complète pour  $\mu$ .

## Estimateurs USBVM

---

Comme  $\mathbb{E}(\bar{X}) = \mu$ , il en découle que  $\bar{X}$  est un estimateur *USBVM* de  $\mu$ , c'est-à-dire qu'il est uniformément sans biais de variance minimale.

Essayons à présent de trouver un estimateur sans biais de variance uniformément minimale de  $\mu^2$ .

L'estimateur naturel  $(\bar{X})^2$  n'est pas satisfaisant puisqu'on a :

$$V(\bar{X}) = \frac{\sigma^2}{n} = \mathbb{E}[(\bar{X})^2] - \mu^2$$

ce qui implique que :

$$\mathbb{E}[(\bar{X})^2] = \mu^2 + \frac{\sigma^2}{n},$$

c'est donc un estimateur biaisé de  $\mu^2$ .

## Estimateurs USBVM

---

Par contre,

$$(\bar{X})^2 - \frac{\sigma^2}{n}$$

est un estimateur sans biais de  $\mu^2$  d'après ce qui précède et, comme il est fonction de la statistique exhaustive complète  $\bar{X}$ , c'est un estimateur UMVUE de  $\mu^2$ .

## Estimateurs USBVM

---

**Remarque.** *Se limiter à considérer des estimateurs sans biais n'est pas toujours une bonne idée.* Pour l'illustrer, considérons un exemple : soit  $X \sim \mathcal{P}(\theta)$  et soit  $X_1$  un échantillon de taille 1 associé à  $X$ .

En mettant la densité de  $X$  sous forme exponentielle, on constate que  $X_1$  est une statistique exhaustive complète pour  $\theta$ .

Or :

$$\begin{aligned}\mathbb{E}[(-1)_1^X] &= \sum_{k=0}^{\infty} (-1)^k \frac{e^{-\theta} \theta^k}{k!} \\ &= e^{-\theta} \sum_{k=0}^{\infty} \frac{(-1)^k}{k!} \\ &= e^{-2\theta}.\end{aligned}$$



## Estimateurs USBVM

---

Ainsi,  $(-1)^{X_1}$  est un estimateur uniformément sans biais de variance minimale de  $e^{-2\theta}$ .

Cependant  $Y \equiv 1$  est clairement un *meilleur* estimateur, puisque 1 est plus proche de  $e^{-2\theta}$  que  $-1$ .

*En fait, estimer une quantité positive à l'aide d'une statistique qui peut prendre des valeurs négatives n'est pas raisonnable.*

Notons également que l'EMV de  $\theta$  n'est autre que  $X_1$  (le démontrer à titre d'exercice).

Par conséquent, l'EMV de  $e^{-2\theta}$  est  $e^{-2X_1}$ , qui semble plus raisonnable que  $Y$ .

## Inégalité de Cramer-Rao

Soit donnée une densité  $f_\theta(x)$ ,  $x \in \mathbb{R}$ ,  $a < \theta < b$ .

On détermine les estimations par maximum de vraisemblance de  $\theta$  en calculant :

$$\frac{\partial}{\partial \theta} \log f_\theta(x).$$

Si on remplace  $x$  par  $X$  dans cette expression, on obtient une *variable aléatoire* :

$$\frac{\partial}{\partial \theta} \log f_\theta(X).$$

Afin d'étudier celle-ci, commençons par un exemple.

## Inégalité de Cramer-Rao

Supposons que  $X$  puisse prendre les valeurs  $x_1, x_2, x_3, x_4$  avec la fonction de masse (densité) :

$$p(x_1) = 0.5, p(x_2) = p(x_3) = 0.2, p(x_4) = 0.1.$$

Alors,  $p(X)$  est une variable aléatoire de loi :

$$\mathbb{P}(p(X) = 0.5) = 0.5$$

$$\mathbb{P}(p(X) = 0.2) = 0.4$$

$$\mathbb{P}(p(X) = 0.1) = 0.1.$$

Le cas continu est, en première approche plus simple : si  $X$  est de densité  $f$  et  $X = x$ , alors  $f(X) = f(x)$ . Mais quelle est la densité de  $f(X)$  ? Nous n'aurons pas besoin de celle-ci mais elle sera déterminée en TD.

## **Inégalité de Cramer-Rao**

Les deux lemmes suivants seront utilisés pour démontrer *l'inégalité de Cramer-Rao*.

Celle-ci peut être utilisée pour obtenir des estimateurs uniformément sans biais de variance minimale (USBVM).

Dans la suite, on supposera systématiquement qu'on peut dériver sous le signe intégrale.

## Inégalité de Cramer-Rao

---

**Lemme 1.** Avec les notations précédentes, on a :

$$\mathbb{E}_\theta \left[ \frac{\partial}{\partial \theta} \log f_\theta(X) \right] = 0.$$

*Preuve.* L'espérance s'écrit :

$$\int_{-\infty}^{+\infty} \left[ \frac{\partial}{\partial \theta} \log f_\theta(x) \right] f_\theta(x) dx = \int_{-\infty}^{+\infty} \frac{1}{f_\theta(x)} \frac{\partial f_\theta(x)}{\partial \theta} \cdot f_\theta(x) dx$$

Elle est donc égale à :

$$\frac{\partial}{\partial \theta} \int_{-\infty}^{+\infty} f_\theta(x) dx = \frac{\partial}{\partial \theta} (1) = 0.$$

## Inégalité de Cramer-Rao

---

**Lemme 2.** Soit  $Y = g(X)$  et supposons que  $\mathbb{E}_\theta(Y) = k(\theta)$ . Si on note  $k'(\theta) = dk(\theta)/d\theta$ , alors :

$$k'(\theta) = \mathbb{E}_\theta \left[ Y \frac{\partial}{\partial \theta} \log f_\theta(X) \right].$$

*Preuve.* On peut écrire :

$$\begin{aligned} k'(\theta) &= \frac{\partial}{\partial \theta} \mathbb{E}_\theta[g(X)] \\ &= \frac{\partial}{\partial \theta} \int_{-\infty}^{+\infty} g(x) f_\theta(x) dx \\ &= \int_{-\infty}^{+\infty} g(x) \frac{\partial f_\theta(x)}{\partial \theta} dx \\ &= \int_{-\infty}^{+\infty} g(x) \frac{\partial f_\theta(x)}{\partial \theta} \frac{1}{f_\theta(x)} f_\theta(x) dx \\ &= \int_{-\infty}^{+\infty} g(x) \left[ \frac{\partial}{\partial \theta} \log f_\theta(x) \right] f_\theta(x) dx \\ &= \mathbb{E}_\theta \left[ g(X) \frac{\partial}{\partial \theta} \log f_\theta(X) \right] \\ &= \mathbb{E}_\theta \left[ Y \frac{\partial}{\partial \theta} \log f_\theta(X) \right]. \end{aligned}$$

## Inégalité de Cramer-Rao

---

### **Théorème (Inégalité de Cramer-Rao).**

Soit  $Y = g(X)$  et supposons que  $\mathbb{E}_\theta(Y) = k(\theta)$ . Si on note  $k'(\theta) = dk(\theta)/d\theta$ , alors :

$$V_\theta(Y) \geq \frac{[k'(\theta)]^2}{\mathbb{E}_\theta \left[ \left( \frac{\partial}{\partial \theta} \log f_\theta(X) \right)^2 \right]}.$$

*Preuve.* Soit  $U, V$  deux v.a.r. de variances bien définies. Alors, en vertu de l'inégalité de Cauchy-Schwarz, nous avons :

$$\begin{aligned} [\text{Cov}(U, W)]^2 &= (\mathbb{E}[(U - \mu_U)(W - \mu_W)])^2 \\ &\leq V(U)V(W). \end{aligned}$$

Par conséquent,

$$[\text{Cov}_\theta(Y, \frac{\partial}{\partial \theta} \log f_\theta(X))]^2 \leq V_\theta(Y)V_\theta \left( \frac{\partial}{\partial \theta} \log f_\theta(X) \right)$$

## Inégalité de Cramer-Rao

Mais, d'après le Lemme 1, on a :

$$\mathbb{E}_\theta \left( \frac{\partial}{\partial \theta} \log f_\theta(X) \right) = 0.$$

Par conséquent, l'inégalité précédente s'écrit :

$$\left( \mathbb{E}_\theta \left[ Y \frac{\partial}{\partial \theta} \log f_\theta(X) \right] \right)^2 \leq V_\theta(Y) \mathbb{E}_\theta \left[ \left( \frac{\partial}{\partial \theta} \log f_\theta(X) \right)^2 \right]$$

ce qui peut s'écrire, d'après le Lemme 2 :

$$[k'(\theta)]^2 \leq V_\theta(Y) \mathbb{E}_\theta \left[ \left( \frac{\partial}{\partial \theta} \log f_\theta(X) \right)^2 \right],$$

d'où le résultat.



## Inégalité de Cramer-Rao pour un échantillon

---

Soit  $X_1, \dots, X_n$  un échantillon i.i.d. de densité commune  $f_\theta(x)$ . Notons :

$$X = (X_1, \dots, X_n).$$

Alors, la densité conjointe de  $X$  est donnée par :

$$f_\theta(x) = \prod_{i=1}^n f_\theta(x_i)$$

et on peut écrire, en vertu du Lemme 1 :

$$\begin{aligned} \mathbb{E}_\theta\left[\left(\frac{\partial}{\partial\theta} \log f_\theta(X)\right)^2\right] &= V_\theta\left(\frac{\partial}{\partial\theta} \log f_\theta(X)\right) \\ &= V_\theta\left(\sum_{i=1}^n \frac{\partial}{\partial\theta} \log f_\theta(X_i)\right) \\ &= n V_\theta\left(\frac{\partial}{\partial\theta} \log f_\theta(X_1)\right) \\ &= n \mathbb{E}_\theta\left[\left(\frac{\partial}{\partial\theta} \log f_\theta(X_1)\right)^2\right]. \end{aligned}$$

On en déduit le théorème suivant.

## Information de Fisher

---

**Théorème.** Soit  $X_1, \dots, X_n$  un échantillon i.i.d. de densité commune  $f_\theta(x)$  et soit  $Y = g(X_1, \dots, X_n)$  un estimateur sans biais de  $\theta$ . Alors :

$$V_\theta(Y) \geq \frac{1}{n \mathbb{E}_\theta[(\frac{\partial}{\partial \theta} \log f_\theta(X_1))^2]},$$

ce qui peut s'écrire également :

$$V_\theta(Y) \geq \frac{1}{n I(\theta)}$$

où  $I(\theta) = \mathbb{E}_\theta[(\frac{\partial}{\partial \theta} \log f_\theta(X_1))^2]$  est appelée l'information de Fisher.

## **Information de Fisher**

---

*Preuve.* Il suffit d'appliquer l'inégalité de Cramer-Rao, avec  $k(\theta) = \theta$ , donc  $k'(\theta) = 1$ .

**Remarque 1.** Il découle de l'inégalité précédente que si  $Y$  est un estimateur sans biais de  $\theta$  pour lequel la borne de Cramer-Rao  $1/nI(\theta)$  est *atteinte pour toute valeur possible de  $\theta$* , c'est-à-dire tel que :

$$V_{\theta}(Y) = \frac{1}{nI(\theta)} \quad \forall \theta$$

alors  $Y$  est nécessairement un estimateur uniformément sans biais de variance minimale de  $\theta$ .

## Information de Fisher

---

**Remarque 2.** Il est souvent plus simple de calculer l'information de Fisher de la façon suivante. On part de la conclusion du Lemme 1, qui s'écrit :

$$\int_{-\infty}^{+\infty} \left( \frac{\partial}{\partial \theta} \log f_{\theta}(x) \right) f_{\theta}(x) dx = 0.$$

On différencie une fois pour obtenir :

$$\int_{-\infty}^{+\infty} \frac{\partial^2 \log f_{\theta}(x)}{\partial \theta^2} f_{\theta}(x) dx + \int_{-\infty}^{+\infty} \frac{\partial \log f_{\theta}(x)}{\partial \theta} \frac{\partial f_{\theta}(x)}{\partial \theta} dx = 0.$$

Ainsi :

$$\int_{-\infty}^{+\infty} \frac{\partial^2 \log f_{\theta}(x)}{\partial \theta^2} f_{\theta}(x) dx + \int_{-\infty}^{+\infty} \frac{\partial \log f_{\theta}(x)}{\partial \theta} \left[ \frac{\partial f_{\theta}(x)}{\partial \theta} \frac{1}{f_{\theta}(x)} \right] f_{\theta}(x) dx = 0$$

## Information de Fisher

---

Mais le terme entre crochet dans la deuxième intégrale n'est autre que :  $\partial \log f_\theta(x) / \partial \theta$ , d'où :

$$\int_{-\infty}^{+\infty} \frac{\partial^2 \log f_\theta(x)}{\partial \theta^2} f_\theta(x) dx + \int_{-\infty}^{+\infty} \left( \frac{\partial \log f_\theta(x)}{\partial \theta} \right)^2 f_\theta(x) dx = 0$$

Par conséquent :

$$\mathbb{E}_\theta \left[ \left( \frac{\partial}{\partial \theta} \log f_\theta(X_1) \right)^2 \right] = -\mathbb{E}_\theta \left[ \frac{\partial^2 \log f_\theta(X_1)}{\partial \theta^2} \right]$$

*Cette dernière expression est souvent plus facile à utiliser pour le calcul de  $I(\theta)$ .*