

## Estimation ponctuelle

### Modèle paramétrique

On observe un échantillon  $(X_1, \dots, X_n)$  où les  $X_j$  sont des v.a. i.i.d.. On parle d'un modèle paramétrique si la loi commune des  $X_j$  appartient à une famille paramètre  $\mathcal{P} = \{\mathbb{P}_\theta, \theta \in \Theta\}$ .

**Exemple 1.** Modèle de Bernoulli:  $\mathcal{P} = \{\mathcal{B}(p), p \in [0, 1]\}$ ,  $\theta = p$ ,  $\Theta = [0, 1]$ .

Modèle Uniforme:  $\mathcal{P} = \{\mathcal{U}([0, \theta]), \theta \in \Theta = \mathbb{R}_+ \setminus \{0\}\}$ .

Modèle Gaussien:  $\mathcal{P} = \{\mathcal{N}(\mu, \sigma^2), \mu \in \mathbb{R}, \sigma^2 \in \mathbb{R}_+ \setminus \{0\}\}$ ,  $\theta = (\mu, \sigma^2)$ ,  $\Theta = \mathbb{R} \times (\mathbb{R}_+ \setminus \{0\})$

### Notations.

- $\mathbb{P}_\theta(X \in A)$  : probabilité que  $X \in A$  lorsque  $X$  suit  $\mathbb{P}_\theta$ .
- $\mathbb{E}_\theta[h(X)]$  : Espérance de  $h(X)$  lorsque  $X$  suit  $\mathbb{P}_\theta$ .
- Si  $X$  est une v.a. discrète, i.e.  $X$  est à valeurs dans un ensemble au plus dénombrable  $X \in \{1, 2, \dots\}$  on note  $\mathbb{P}_\theta(X = x) = p(x, \theta)$ .
- Si  $X$  est une v.a. continue alors on notera  $f(x, \theta)$  la densité de  $X$  selon  $\mathbb{P}_\theta$ .
- Soit  $X = (X_1, \dots, X_n)$  un échantillon de taille  $n$  où les  $X_j$  sont i.i.d.

1. Dans le cas discret:  $\mathbb{P}_\theta(X = x) = p(x, \theta) = \prod_{j=1}^n p(x_j, \theta)$

2. Dans le cas continu:  $f(x, \theta) = \prod_{j=1}^n f(x_j, \theta)$

ou  $x = (x_1, \dots, x_n)$  est la réalisation de l'échantillon  $X = (X_1, \dots, X_n)$ .

**Exemple 2.** Dans le modèle de Bernoulli  $(X_1, \dots, X_n)$  un échantillon de  $n$  v.a. i.i.d.  $\sim \mathcal{B}(p)$ , où  $p \in [0, 1]$ ,

$$p(x, p) = \prod_{j=1}^n p(x_j, p) = \prod_{j=1}^n [p^{x_j}(1-p)^{1-x_j}] = p^{\sum_{j=1}^n x_j} (1-p)^{n - \sum_{j=1}^n x_j}.$$

Dans le modèle Gaussien

$$f(x, \mu, \sigma^2) = \prod_{j=1}^n f(x_j, \mu, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-\frac{1}{2\sigma^2} \sum_{j=1}^n (x_j - \mu)^2}$$

**Définition 3.** On appelle statistique toute v.a.  $S$  qui dépend de l'échantillon  $(X_1, \dots, X_n)$  mais qui ne fait pas intervenir le paramètre  $\theta$ .

**Exemple 4.** Quelques statistiques:

- $\sum_{j=1}^n X_j$
- $\bar{X}_n$  (la moyenne empirique)
- $\max_{1 \leq j \leq n} (X_j)$

$$- \frac{1}{n} \sum_{j=1}^n (X_j - \bar{X}_n)^2 \text{ (variance empirique)}$$

Mais  $\theta X_1$  et  $(\bar{X}_n + \theta^2 \max_{1 \leq j \leq n} (X_j))$  ne sont pas des statistique.

## Estimation ponctuelle

**Définition 5.** Soit  $g$  une application sur  $\Theta$ . On appelle estimateur (ponctuel) de  $g(\theta)$  toute statistique  $T$  prenant ses valeurs dans  $g(\Theta)$ .

**Exemple 6.** Dans le modèle de Bernoulli  $\mathcal{P} = \{\mathcal{B}(p), p \in [0, 1]\}$  la moyenne empirique  $\bar{X}_n$  est un estimateur de  $p$  ( $g(p) = p$  c-à-d  $g$  est l'identité sur  $\Theta = [0, 1]$ ).

Dans le modèle Gaussien  $\mathcal{P} = \{\mathcal{N}(\mu, \sigma^2), (\mu, \sigma^2) \in \mathbb{R} \times \mathbb{R}_+^*\}$  la variance empirique

$$S_n^2 = \frac{1}{n} \sum_{j=1}^n (X_j - \bar{X}_n)^2$$

est un estimateur de  $\sigma^2$  ( $g(\mu, \sigma^2) = \sigma^2$ ) et  $S_n = \sqrt{S_n^2}$  (l'écart-type empirique) est un estimateur de  $\sigma$  (l'écart-type théorique).

## Quelques propriétés des estimateurs

**Définition 7.** Un estimateur  $T$  de  $g(\theta)$  est dit sans biais (ou non biaisé) si  $\mathbb{E}_\theta[T] = g(\theta)$ . Autrement, le biais  $b(\theta) = \mathbb{E}_\theta[T] - g(\theta) = 0$ .

**Définition 8.** On appelle risque quadratique d'un estimateur  $T$ , et on note  $R(T, \theta)$  la quantité  $R(T, \theta) = \mathbb{E}_\theta[(T - g(\theta))^2]$ . En particulier, si  $T$  est sans biais alors  $R(T, \theta) = \mathbb{E}_\theta[(T - \mathbb{E}_\theta[T])^2] = \text{Var}_\theta(T)$ .

**Remarque 9.** On peut toujours écrire

$$R(T, \theta) = \text{Var}_\theta(T) + (b(\theta))^2$$

donc dans le risque il y a une partie due à la variance de la statistique et un autre du à son biais. En effet

$$\begin{aligned} R(T, \theta) &= \mathbb{E}_\theta[(T - g(\theta))^2] = \mathbb{E}_\theta[((T - \mathbb{E}_\theta[T]) + (\mathbb{E}_\theta[T] - g(\theta)))^2] \\ &= \mathbb{E}_\theta[(T - \mathbb{E}_\theta[T])^2 + 2(\mathbb{E}_\theta[T] - g(\theta))(T - \mathbb{E}_\theta[T]) + (\mathbb{E}_\theta[T] - g(\theta))^2] \\ &= \mathbb{E}_\theta[(T - \mathbb{E}_\theta[T])^2] + 2b(\theta)\mathbb{E}_\theta[T - \mathbb{E}_\theta[T]] + (b(\theta))^2 \\ &= \text{Var}_\theta(T) + (b(\theta))^2 \end{aligned}$$

**Définition 10.** Soient  $T_1$  et  $T_2$  deux estimateurs non biaisés de  $g(\theta)$ . On dira que  $T_2$  est plus efficace de  $T_1$  si  $R(T_2, \theta) \leq R(T_1, \theta)$  pour tout  $\theta \in \Theta$ , c-à-d  $\text{Var}_\theta(T_2) \leq \text{Var}_\theta(T_1)$  pour tout  $\theta \in \Theta$ .

**Exemple 11.** Reprenons l'exemple du modèle de Bernoulli  $\mathcal{P} = \{\mathcal{B}(p), p \in [0, 1]\}$ . Comparons les estimateurs  $X_1$  et  $\bar{X}_n$  (Il s'agit d'estimer le paramètre  $p$ ).

$\mathbb{E}[X_1] = p$  donc  $X_1$  est un estimateur non biaisé de  $p$ .

$\mathbb{E}[\bar{X}_n] = p \Rightarrow \bar{X}_n$  est aussi un estimateur non biaisé de  $p$ .

$R(X_1, p) = \text{Var}_p(X_1) = p(1 - p)$

$$R(\bar{X}_n, p) = \text{Var}_p(\bar{X}_n) = (\text{Var}_p(X_1) + \dots + \text{Var}_p(X_n))/n^2 = p(1-p)/n$$

On en déduit que  $\text{Var}_p(\bar{X}_n) \leq \text{Var}_p(X_1)$  pour tout  $p \in [0, 1]$  donc  $\bar{X}_n$  est un estimateur plus efficace que  $X_1$ .

**Exemple 12.** Modèle Uniforme.  $\mathcal{P} = \{\mathcal{U}([0, \theta]), \theta \in \mathbb{R}_+^*\}$ ,  $f(x, \theta) = \theta^{-1}\mathbb{I}_{x \in [0, \theta]}$ . On considère les estimateurs suivants:  $T_1 = 2\bar{X}_n$  et  $T_2 = [(n+1)/n]\max_{1 \leq j \leq n} X_j$ .

On observe un échantillon de taille  $n$ . Montrons que ces estimateurs sont non biaisés:

$$\mathbb{E}_\theta[2\bar{X}_n] = 2\mathbb{E}_\theta[X_1] = 2\frac{\theta}{2} = \theta \text{ (non biaisé)}$$

On pose  $Y = \max_{1 \leq j \leq n} X_j$ . Soit  $y \in \mathbb{R}$ ,

$$\mathbb{P}_\theta(Y \leq y) = \mathbb{P}_\theta(X_1 \leq y, \dots, X_n \leq y) = \mathbb{P}_\theta(X_1 \leq y)^n = \begin{cases} 0 & \text{si } y \leq 0 \\ (y/\theta)^n & \text{si } y \in [0, \theta] \\ 1 & \text{si } y > \theta \end{cases}$$

Donc  $Y$  admet pour densité la fonction  $g(y, \theta)$  donnée par

$$g(y, \theta) = \frac{n}{\theta^n} y^{n-1} \mathbb{I}_{0 \leq y \leq \theta}$$

et

$$\mathbb{E}_\theta[Y] = \int_0^\theta \frac{n}{\theta^n} y^n dy = \frac{n}{n+1} \theta$$

ce qui donne

$$\mathbb{E}_\theta[T_2] = \frac{n+1}{n} \mathbb{E}_\theta[Y] = \theta$$

et par conséquent  $T_2$  est un estimateur non biaisé de  $\theta$ . Calculons les variances respectives de  $T_1$  et  $T_2$ :

$$\text{Var}_\theta(T_1) = 4\text{Var}_\theta(\bar{X}_n) = \frac{4}{n} \text{Var}_\theta(X_1) = \frac{\theta^2}{3n}$$

et

$$\text{Var}_\theta(T_2) = \left(\frac{n+1}{n}\right)^2 \text{Var}_\theta(Y) = \left(\frac{n+1}{n}\right)^2 \left[ \mathbb{E}_\theta[Y^2] - \left(\frac{n}{n+1}\right)^2 \theta^2 \right]$$

Or

$$\mathbb{E}_\theta[Y^2] = \int_0^\theta \frac{n}{\theta^n} y^{n+1} dy = \frac{n}{n+2} \theta^2$$

donc

$$\text{Var}_\theta(T_2) = \left(\frac{n+1}{n}\right)^2 \left[ \frac{n}{n+2} - \left(\frac{n}{n+1}\right)^2 \right] \theta^2 = \frac{\theta^2}{n(n+2)}$$

et

$$\frac{\text{Var}_\theta(T_2)}{\text{Var}_\theta(T_1)} = \frac{3}{n+2} \leq 1$$

qui montre que  $T_2$  est plus efficace que  $T_1$ .

**Définition 13.** Soit l'application  $g: \Theta \rightarrow \mathbb{R}^d$ . On dit que la suite  $(T_n)_{n \geq 1}$  d'estimateurs de  $g(\theta)$  est

1. *Convergente:* si  $(T_n)_{n \geq 1}$  converge en probabilité vers  $g(\theta)$  pour tout  $\theta \in \Theta$ .

2. *Fortement convergente*: si  $(T_n)_{n \geq 1}$  converge presque sûrement vers  $g(\theta)$  pour tout  $\theta \in \Theta$ .
3. *Asymptotiquement normale*: si pour tout  $\theta \in \Theta$  existe une matrice de covariance  $\Sigma(\theta)$  telle que  $\sqrt{n}(T_n - g(\theta)) \xrightarrow{\mathcal{L}} \mathcal{N}_d(0, \Sigma(\theta))$ .

**Exemple 14.** Soient  $X_1, \dots, X_n$  un échantillon de loi  $\mathcal{B}(p)$ . D'après la loi forte des grandes nombres

$$\bar{X}_n \xrightarrow{p.s.} p \quad \text{pour tout } p \in [0, 1]$$

la suite  $(X_n)_{n \geq 1}$  est fortement convergente. De plus  $\text{Var}_p(X_1) = p(1-p) < +\infty$  et d'après le TCL

$$\sqrt{n}(\bar{X}_n - p) \xrightarrow{\mathcal{L}} \mathcal{N}(0, p(1-p))$$

la suite  $(X_n)_{n \geq 1}$  est asymptotiquement normale avec  $\Sigma(p) = p(1-p)$ .

### Exhaustivité

**Définition 15.** Une statistique  $S$  est dite exhaustive si la loi conditionnelle de  $X = (X_1, \dots, X_n)$  sachant  $S = s$  ne dépend pas du paramètre  $\theta$  pour tout  $s$ .

**Théorème 16.** (De factorisation)  $S$  est une statistique exhaustive ssi il existe des applications  $g$  et  $h$  telles que

$$p(\mathbf{x}, \theta) = g(\mathbf{x}) h(S(\mathbf{x}), \theta) \quad \text{dans le cas discret}$$

$$f(\mathbf{x}, \theta) = g(\mathbf{x}) h(S(\mathbf{x}), \theta) \quad \text{dans le cas continu}$$

**Rappel.**  $p(\mathbf{x}, \theta) = \prod_{j=1}^n p(x_j, \theta)$  et  $f(\mathbf{x}, \theta) = \prod_{j=1}^n f(x_j, \theta)$

**Démonstration.** (Uniquement dans le cas discret). ( $\Rightarrow$ ) Supposons que  $S$  est exhaustive.  $p(\mathbf{x}, \theta) = \mathbb{P}_\theta(\mathbf{X} = \mathbf{x}) = \mathbb{P}_\theta(\mathbf{X} = \mathbf{x} \mid S(\mathbf{X}) = S(\mathbf{x}))$  car  $\{S(\mathbf{X}) = S(\mathbf{x})\} \supseteq \{\mathbf{X} = \mathbf{x}\}$ . Donc  $\mathbb{P}_\theta(\mathbf{X} = \mathbf{x}) = \mathbb{P}_\theta(\mathbf{X} = \mathbf{x} \mid S(\mathbf{X}) = S(\mathbf{x})) \mathbb{P}_\theta(S(\mathbf{X}) = S(\mathbf{x}))$ . Or  $S$  est exhaustive  $\Rightarrow \mathbb{P}_\theta(\mathbf{X} = \mathbf{x} \mid S(\mathbf{X}) = S(\mathbf{x}))$  ne dépend pas de  $\theta$ :  $\mathbb{P}_\theta(\mathbf{X} = \mathbf{x} \mid S(\mathbf{X}) = S(\mathbf{x})) = \mathbb{P}(\mathbf{X} = \mathbf{x} \mid S(\mathbf{X}) = S(\mathbf{x}))$  et on pose  $g(\mathbf{x}) = \mathbb{P}(\mathbf{X} = \mathbf{x} \mid S(\mathbf{X}) = S(\mathbf{x}))$  et  $h(s, \theta) = \mathbb{P}_\theta(S(\mathbf{X}) = s)$ . Il vient que

$$p(\mathbf{x}, \theta) = \mathbb{P}(\mathbf{X} = \mathbf{x} \mid S(\mathbf{X}) = S(\mathbf{x})) \mathbb{P}_\theta(S(\mathbf{X}) = S(\mathbf{x})) = g(\mathbf{x}) h(S(\mathbf{x}), \theta).$$

( $\Leftarrow$ ) Réciproquement, supposons qu'il existe  $g$  et  $h$  telles que

$$p(\mathbf{x}, \theta) = g(\mathbf{x}) h(S(\mathbf{x}), \theta)$$

et montrons que  $S$  est exhaustive. Fixons  $s$ . On pose  $A_s = \{\mathbf{y} : S(\mathbf{y}) = s\}$ .

$$\mathbb{P}_\theta(S(\mathbf{X}) = s) = \sum_{\mathbf{x} \in A_s} \mathbb{P}_\theta(\mathbf{X} = \mathbf{x}) = \sum_{\mathbf{x} \in A_s} g(\mathbf{x}) h(S(\mathbf{x}), \theta) = h(s, \theta) \sum_{\mathbf{x} \in A_s} g(\mathbf{x})$$

$$\mathbb{P}_\theta(\mathbf{X} = \mathbf{x} \mid S(\mathbf{X}) = s) = \frac{\mathbb{P}_\theta(\mathbf{X} = \mathbf{x}, S(\mathbf{X}) = s)}{\mathbb{P}_\theta(S(\mathbf{X}) = s)} = \begin{cases} 0 & \text{si } s \neq S(\mathbf{x}) \\ \frac{\mathbb{P}_\theta(\mathbf{X} = \mathbf{x})}{\mathbb{P}_\theta(S(\mathbf{X}) = s)} & \text{si } s = S(\mathbf{x}) \end{cases}$$

Si  $s = S(\mathbf{x})$

$$\frac{\mathbb{P}_\theta(\mathbf{X} = \mathbf{x})}{\mathbb{P}_\theta(S(\mathbf{X}) = s)} = \frac{g(\mathbf{x}) h(s, \theta)}{h(s, \theta) \sum_{\mathbf{x} \in A_s} g(\mathbf{x})} = \frac{g(\mathbf{x})}{\sum_{\mathbf{x} \in A_s} g(\mathbf{x})}$$

donc

$$\mathbb{P}_\theta(\mathbf{X} = \mathbf{x} | S(\mathbf{X}) = s) = \begin{cases} 0 & \text{si } s \neq S(\mathbf{x}) \\ \frac{g(\mathbf{x})}{\sum_{\mathbf{x} \in A_s} g(\mathbf{x})} & \text{si } s = S(\mathbf{x}) \end{cases}$$

qui ne dépend pas de  $\theta$  et qui donne l'exhaustivité de  $S$ . □

**Exemple 17.** Soit  $\mathbf{X} = (X_1, \dots, X_n)$  un échantillon de Bernoulli de paramètre  $p$  et  $S(\mathbf{X}) = \sum_{j=1}^n X_j$ . Montrons que  $S$  est exhaustive pour  $p$ .

$$p(\mathbf{x}, \theta) = \prod_{j=1}^n p^{x_j} (1-p)^{1-x_j} = p^{\sum_{j=1}^n x_j} (1-p)^{n - \sum_{j=1}^n x_j} = g(\mathbf{x}) h(S(\mathbf{x}), p)$$

avec  $g(\mathbf{x}) = 1$  et  $h(s, p) = p^s (1-p)^{n-s}$ . Par le théorème de factorisation on en déduit que  $S$  est exhaustive pour  $p$ .

**Exemple 18.** Soit  $\mathbf{X} = (X_1, \dots, X_n)$  un échantillon Gaussien de moyenne  $\mu$  et variance  $\sigma^2$ . On pose

$$S(\mathbf{X}) = \left( \sum_{j=1}^n X_j, \sum_{j=1}^n X_j^2 \right).$$

Montrons que  $S$  est exhaustive pour  $(\mu, \sigma^2)$ :

$$\begin{aligned} f(\mathbf{x}, \theta) &= \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-\frac{1}{2\sigma^2} \sum_{j=1}^n (x_j - \mu)^2} = \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-\frac{1}{2\sigma^2} \sum_{j=1}^n (x_j^2 - 2\mu x_j + \mu^2)} \\ &= \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-\frac{1}{2\sigma^2} (\sum_{j=1}^n x_j^2 - 2\mu \sum_{j=1}^n x_j + n\mu^2)} = g(\mathbf{x}) h(S(\mathbf{X}), (\mu, \sigma^2)) \end{aligned}$$

où  $g(\mathbf{x}) = 1$  et

$$h((s_1, s_2), (\mu, \sigma^2)) = \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-\frac{1}{2\sigma^2} (s_2 - 2\mu s_1 + n\mu^2)}$$

Par le théorème de factorisation on en déduit que  $S$  est exhaustive pour  $(\mu, \sigma^2)$ .

## Méthodes d'estimation

### Méthode des moments

**Définition 19.** Soit  $r \in \mathbb{N}^*$ . Si  $X$  est une v.a. réelle t.a.  $\mathbb{E}[|X|^r] < +\infty$  alors on appelle  $\mathbb{E}[X^r]$  le moment d'ordre  $r$  de  $X$  et on le note  $m_r$ .

**Définition 20.** On appelle moment empirique d'ordre  $r$  la statistique

$$\frac{1}{n} \sum_{j=1}^n (X_j)^r$$

que on notera  $M_{r,n}$ .

**Exemple 21.**  $M_{1,n} = \bar{X}_n$  et  $M_{2,n} = n^{-1} \sum_{j=1}^n X_j^2$ .

**Définition 22.** Soit  $\theta = (\theta_1, \dots, \theta_d) \in \Theta \subseteq \mathbb{R}^d$ . On suppose que  $X$  est une v.a. réelle telle que  $\mathbb{E}[|X|^d] < +\infty$ . S'il existe des applications  $\varphi_1, \dots, \varphi_d$  telles que  $\theta_j = \varphi_j(m_1, m_2, \dots, m_d)$ , alors l'estimateur obtenu par la méthode des moments est donnée par

$$\hat{\theta}_n = (\varphi_1(M_{1,n}, \dots, M_{d,n}), \dots, \varphi_d(M_{1,n}, \dots, M_{d,n})).$$

**Exemple 23.**  $X \sim \mathcal{P}(\lambda)$ ,  $\lambda > 0$ .  $\lambda = \mathbb{E}[X] = m_1$ . L'estimateur de  $\lambda$  obtenu par la méthode des moments est

$$\hat{\lambda}_n = M_{1,n} = \bar{X}_n.$$

**Exemple 24.**  $X \sim \mathcal{N}(\mu, \sigma^2)$ .  $\mu = \mathbb{E}[X] = m_1$  et  $\sigma^2 = \text{Var}(X) = \mathbb{E}[X^2] - (\mathbb{E}[X])^2 = m_2 - m_1^2$ . L'estimateur de  $\theta = (\mu, \sigma^2)$  obtenu par la méthode des moments est  $\hat{\theta}_n = (\hat{\mu}_n, \hat{\sigma}_n^2)$  où  $\hat{\mu}_n = M_{1,n} = \bar{X}_n$  et  $\hat{\sigma}_n^2 = M_{2,n} - M_{1,n}^2$ :

$$\hat{\sigma}_n^2 = M_{2,n} - M_{1,n}^2 = \frac{1}{n} \sum_{j=1}^n X_j^2 - \bar{X}_n^2 = \frac{1}{n} \sum_{j=1}^n (X_j - \bar{X}_n)^2 = S_n^2$$

la variance empirique.

## Méthode de maximum de vraisemblance

**Définition 25.** Soit  $\mathbf{x} = (x_1, \dots, x_n)$  une réalisation d'un échantillon  $\mathbf{X} = (X_1, \dots, X_n)$  de  $n$  v.a. iid. La fonction  $L_n(\mathbf{x}, \theta)$  (ou  $L_n(\theta)$ ) donnée par

- $L_n(\theta) = L_n(\mathbf{x}, \theta) = p(\mathbf{x}, \theta) = \prod_{j=1}^n p(x_j, \theta)$  dans le cas discret
- $L_n(\theta) = L_n(\mathbf{x}, \theta) = f(\mathbf{x}, \theta) = \prod_{j=1}^n f(x_j, \theta)$  dans le cas continu

vue comme fonction de  $\theta$  pour  $\mathbf{x}$  fixé, s'appelle la vraisemblance de la réalisation  $\mathbf{x} = (x_1, \dots, x_n)$ .

**Définition 26.** On suppose que pour toute réalisation  $\mathbf{x} = (x_1, \dots, x_n)$  il existe une unique valeur  $\hat{\theta}_n(\mathbf{x})$  qui maximise la vraisemblance  $L_n(\mathbf{x}, \theta)$ . Alors la statistique  $\hat{\theta}_n(\mathbf{X})$  est appelée l'estimateur de maximum de vraisemblance (EMV) du paramètre  $\theta$ . Il revient au même de maximiser la vraisemblance ou son logarithme, c-à-d la log-vraisemblance, souvent notée  $\ell_n(\theta)$  ou  $\ell_n(\mathbf{x}, \theta)$ , i.e.

$$\ell_n(\mathbf{x}, \theta) = \ell_n(\theta) = \log L_n(\theta) = \begin{cases} \sum_{j=1}^n \log(p(x_j, \theta)) & \text{dans le cas discret;} \\ \sum_{j=1}^n \log(f(x_j, \theta)) & \text{dans le cas continu.} \end{cases}$$

**Remarque 27.** Pour chercher l'EMV, on cherchera les solutions de l'équation

$$\left( \frac{\partial \ell_n}{\partial \theta_1}, \dots, \frac{\partial \ell_n}{\partial \theta_d} \right) = (0, \dots, 0)$$

et vérifier que la matrice Hessienne

$$\left( \frac{\partial^2 \ell_n}{\partial \theta_i \partial \theta_j} \right)_{i,j=1,\dots,d}$$

est définie négative (on a supposé que  $\theta \mapsto \ell_n(\theta)$  est  $C^2(\Theta)$ ).

**Exemple 28.** Soit  $\mathbf{X} = (X_1, \dots, X_n)$  un échantillon Bernoulli de paramètre  $p \in [0, 1]$ .

$$L_n(\mathbf{x}, p) = p^{\sum_{j=1}^n x_j} (1-p)^{n - \sum_{j=1}^n x_j}$$

$$\ell_n(\mathbf{x}, p) = \sum_{j=1}^n x_j \log(p) + \left( n - \sum_{j=1}^n x_j \right) \log(1-p)$$

$$\frac{\partial \ell_n(\mathbf{x}, p)}{\partial p} = \sum_{j=1}^n x_j \frac{1}{p} - \left( n - \sum_{j=1}^n x_j \right) \frac{1}{1-p}$$

$$\frac{\partial \ell_n(\mathbf{x}, p)}{\partial p} = 0 \iff \sum_{j=1}^n x_j \frac{1}{p} - \left( n - \sum_{j=1}^n x_j \right) \frac{1}{1-p} = 0$$

qui donne:

$$p = \frac{1}{n} \sum_{j=1}^n x_j$$

Donc  $\frac{\partial \ell_n(\mathbf{x}, p)}{\partial p} = 0$  admet unique solution  $\hat{p}_n = \frac{1}{n} \sum_{j=1}^n x_j = \bar{x}_n$  et

$$\frac{\partial^2 \ell_n(\mathbf{x}, p)}{\partial p^2} = - \sum_{j=1}^n x_j \frac{1}{p^2} - \left( n - \sum_{j=1}^n x_j \right) \frac{1}{(1-p)^2} < 0$$

ce qu'implique que  $\hat{p}_n$  est un maximum globale de  $p \mapsto \ell_n(\mathbf{x}, p)$  et que l'EMV de  $p$  est  $\bar{X}_n$ .

## Eléments de théorie de l'information

Dans cette section on supposera toujours que  $\Theta \subseteq \mathbb{R}^d$ ,  $\Theta$  ouvert et  $d \geq 1$ .

**Définition 29.** On appelle score la fonction  $S(x, \theta) = (S_1(x, \theta), \dots, S_d(x, \theta))$  à valeurs dans  $\mathbb{R}^d$  où

$$S_i(x, \theta) = \frac{\partial}{\partial \theta_i} \ell_n(x, \theta), \quad i = 1, \dots, d.$$

On appelle information de Fisher (apporté par  $X$  sur  $\theta$ ) la matrice symétrique  $I(\theta)$  de dimension  $d \times d$  donnée par

$$I(\theta)_{ij} = \mathbb{E}_\theta[S_i(X, \theta)S_j(X, \theta)] = \mathbb{E}_\theta \left[ \frac{\partial}{\partial \theta_i} \ell_n(X, \theta) \frac{\partial}{\partial \theta_j} \ell_n(X, \theta) \right], \quad i, j = 1, \dots, d.$$

**Remarque 30.** On a que  $I(\theta) = \mathbb{E}_\theta[S(X, \theta)S(X, \theta)^T]$ .

**Exemple 31.** (Exponentielle)  $X \sim \mathcal{E}(\lambda)$ ,  $\lambda > 0$ .  $\lambda = \theta \in \Theta = ]0, +\infty[$ ,  $d = 1$ .

$$f(x, \lambda) = \lambda e^{-\lambda x} \mathbb{I}_{x>0}$$

Soit  $x > 0$ :

$$S(x, \lambda) = \frac{d}{d\lambda} \log f(x, \lambda) = \frac{1}{\lambda} - x$$

$$I(\lambda) = \mathbb{E}_\lambda[S(X, \lambda)^2] = \mathbb{E}_\lambda \left[ \left( X - \frac{1}{\lambda} \right)^2 \right] = \text{Var}_\lambda(X) = \frac{1}{\lambda^2}$$

**Exemple 32.** (Gaussienne)  $X \sim \mathcal{N}(\mu, v)$ ,  $\theta = (\mu, v) \in \Theta = \mathbb{R} \times \mathbb{R}_+^*$ ,  $d = 2$ .

$$\ell_n(\mu, v) = \log f(x, \mu, v) = -\frac{1}{2} \log(2\pi) - \frac{1}{2} \log v - \frac{1}{2} \frac{(x - \mu)^2}{v}$$

$$S_1(\mu, v) = \frac{\partial}{\partial \mu} \ell_n(\mu, v) = \frac{x - \mu}{v}$$

$$S_2(\mu, v) = \frac{\partial}{\partial v} \ell_n(\mu, v) = -\frac{1}{2v} + \frac{1}{2} \frac{(x - \mu)^2}{v^2}$$

$$I(\mu, v)_{11} = \mathbb{E}_{\mu, v} \left[ \frac{(x - \mu)^2}{v^2} \right] = \frac{1}{v}$$

$$I(\mu, v)_{11} = \mathbb{E}_{\mu, v} \left[ \frac{(x - \mu)}{v} \left( \frac{1}{2v} - \frac{1}{2} \frac{(x - \mu)^2}{v^2} \right) \right] = \mathbb{E}_{\mu, v} \left[ \frac{(x - \mu)}{2v^2} - \frac{1}{2} \frac{(x - \mu)^3}{v^3} \right] = 0$$

par symétrie, et

$$\begin{aligned} I(\mu, v)_{22} &= \mathbb{E}_{\mu, v} \left[ \left( -\frac{1}{2v} + \frac{1}{2} \frac{(x - \mu)^2}{v^2} \right)^2 \right] = \frac{1}{4v^2} - \frac{1}{2v} \mathbb{E}_{\mu, v} \left[ \frac{(x - \mu)^2}{v^2} \right] + \frac{1}{4} \mathbb{E}_{\mu, v} \left[ \frac{(x - \mu)^4}{v^4} \right] \\ &= \frac{1}{4v^2} - \frac{1}{2v^2} + \frac{3}{4v^2} = \frac{1}{2v^2}. \end{aligned}$$

Donc

$$I(\mu, v) = \begin{pmatrix} \frac{1}{v} & 0 \\ 0 & \frac{1}{2v^2} \end{pmatrix}$$

est l'information de Fisher apportée par  $X$  sur  $(\mu, v)$ .

Soit  $X$  une variable aléatoire à valeurs dans  $\mathcal{X}$ . Par exemple  $\mathcal{X} = \mathbb{R}$  si  $X$  est une v.a. réelle,  $\mathcal{X} = \mathbb{R}^n$  si  $X$  est une v.a. vectorielle de dimension  $n$ .

**Théorème 33.** (cas discret) On suppose

**H1.**  $\{x \in \mathcal{X} : p(x, \theta) > 0\}$  ne dépend pas de  $\theta \in \Theta$  ;

**H2.** La fonction  $\theta \mapsto p(x, \theta)$  est  $C^2(\Theta)$  ;



**H3.**  $\forall A \subseteq \mathcal{X}$

$$\frac{\partial}{\partial \theta_i} \sum_{x \in A} p(x, \theta) = \sum_{x \in A} \frac{\partial}{\partial \theta_i} p(x, \theta), \quad i = 1, \dots, d;$$

$$\frac{\partial^2}{\partial \theta_i \partial \theta_j} \sum_{x \in A} p(x, \theta) = \sum_{x \in A} \frac{\partial^2}{\partial \theta_i \partial \theta_j} p(x, \theta), \quad i, j = 1, \dots, d.$$

Alors

$$\mathbb{E}[S(X, \theta)] = 0 \quad \text{et} \quad I(\theta)_{ij} = -\mathbb{E}_\theta \left[ \frac{\partial^2}{\partial \theta_i \partial \theta_j} \log p(X, \theta) \right] = -\mathbb{E}_\theta \left[ \frac{\partial}{\partial \theta_i} S_j(X, \theta) \right].$$

**Remarque 34.** Dans le cas continu on remplace partout  $p(x, \theta)$  par  $f(x, \theta)$  et  $\sum_{x \in A} g(x)$  par  $\int_A g(x) dx$ .

### Cas des familles exponentielles

**Définition 35.** Un modèle  $\mathcal{P} = \{\mathbb{P}_\theta : \theta \in \Theta\}$  est dit appartenir à une famille exponentielle si existent un entier  $r \geq 1$  et des fonctions

$$c(\theta) > 0, \quad h(x) > 0, \quad \alpha_j(\theta), \Gamma_j(\theta) \text{ pour } j = 1, \dots, r,$$

telles que

$$p(x, \theta) = c(\theta) h(x) \exp \left( \sum_{i=1}^r \alpha_i(\theta) \Gamma_i(x) \right).$$

**Exemple 36.** (Bernoulli)  $X \sim \text{Ber}(p)$ .  $p \in ]0, 1[$ .

$$p(x, \theta) = \theta^x (1-\theta)^{1-x} = e^{x \log \theta + (1-x) \log(1-\theta)} = e^{x \log(\theta/(1-\theta)) + \log(1-\theta)} \quad \text{pour } x = 0, 1$$

et donc  $r = 1$ ,  $c(\theta) = (1-\theta)$ ,  $h(x) = 1$ ,  $\alpha_1(\theta) = \log(\theta/(1-\theta))$ ,  $\Gamma_1(x) = x$ .

**Exemple 37.** (Gaussienne)  $X \sim \mathcal{N}(\mu, \sigma^2)$ .

$$f(x, \theta) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

$$c(\theta) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{\mu^2}{2\sigma^2}}, \quad h(x) = 1$$

$$\alpha_1(\theta) = \frac{\mu}{\sigma^2}, \quad \Gamma_1(x) = x$$

$$\alpha_2(\theta) = -\frac{1}{2\sigma^2}, \quad \Gamma_2(x) = x^2$$

Donc soit  $\text{Ber}(p)$  que  $\mathcal{N}(\mu, \sigma^2)$  appartiennent à des familles exponentielles.

**Exemple 38.**  $X \sim \mathcal{G}(a, b)$ .  $(a, b) = \theta \in \Theta = ]1, +\infty[ \times \mathbb{R}_+^*$

$$f(x, a, b) = \frac{b^a}{\Gamma(a)} x^{a-1} e^{-bx} \mathbb{I}_{x>0}$$

$h(x) = \mathbb{I}_{x>0}$ ,  $c(a, b) = b^a/\Gamma(a)$ ,  $\Gamma_1(x) = \log x$ ,  $\Gamma_2(x) = -x$ ,  $\alpha_1(a, b) = a - 1$ ,  $\alpha_2(a, b) = b$ .

**Théorème 39.** Soit  $\mathcal{P}$  un modèle paramétrique appartenant à une famille exponentielle. Si les fonctions  $\alpha_i(\theta)$ ,  $i = 1, \dots, d$  sont  $C^2(\Theta)$  alors les hypothèses **H1**, **H2**, **H3** sont vérifiées.

**Exemple 40.** (Bernoulli, suite de l'exemple 36)  $r = 1$ ,  $\alpha_1(p) = \log(p/(1-p))$  est  $C^2(]0, 1[)$  donc **H1**, **H2**, **H3** sont vérifiées.

$$S(x, p) = \frac{d}{dp} \log p(x, p) = \frac{x}{p} - \frac{1-x}{1-p}$$

$$\frac{d^2}{dp^2} \log p(x, p) = -\frac{x}{p^2} - \frac{1-x}{(1-p)^2}$$

Par le théorème 33 on a que

$$0 = \mathbb{E}_p[S(X, p)]$$

et que

$$I(p) = \mathbb{E}_p \left[ \frac{x}{p^2} + \frac{1-x}{(1-p)^2} \right] = \frac{p}{p^2} + \frac{1-p}{(1-p)^2} = \frac{1}{p} + \frac{1}{1-p} = \frac{1}{p(1-p)}$$

pour tout  $p \in ]0, 1[$ .

**Théorème 41.** (Borne de Cramer-Rao) Ici  $d = 1$ . Soit  $g: \Theta \rightarrow \mathbb{R}$  une fonction  $C^1(\Theta)$  et  $T_n(\mathbf{X})$  un estimateur non biaisé de  $g(\theta)$ . Si  $\mathcal{P}$  vérifie les hypothèses **H1**, **H2**, **H3** et en plus on a que

i.  $0 < I(\theta) < +\infty$ .

ii.

$$g'(\theta) = \begin{cases} \sum_{\mathbf{x} \in \mathcal{X}^n} T(\mathbf{x}) \frac{\partial}{\partial \theta} p(\mathbf{x}, \theta) & \text{dans le cas discret;} \\ \int T(\mathbf{x}) \frac{\partial}{\partial \theta} p(\mathbf{x}, \theta) d\mathbf{x} & \text{dans le cas continu.} \end{cases}$$

Alors

$$\text{Var}_\theta(T_n(\mathbf{X})) \geq \frac{(g'(\theta))^2}{nI(\theta)}.$$

**Remarque 42.** Si  $\text{Var}_\theta(T_n(\mathbf{X})) = \frac{(g'(\theta))^2}{nI(\theta)}$  alors on dit que l'estimateur  $T_n$  est (uniformément) efficace.

**Exemple 43.** Soit  $X \sim \mathcal{N}(\mu, 1)$ ,  $\theta = \mu \in \Theta = \mathbb{R}$ . Le modèle appartient à une famille exponentielle avec  $r = 1$  et  $\alpha_1(x) = x$ . Donc  $\alpha_1$  est  $C^2(\Theta)$  et les hypothèses **H1**, **H2**, **H3** sont vérifiées et donc

$$I(\mu) = -\mathbb{E} \frac{d^2}{d\mu^2} \log f(X, \mu) = 1$$

car

$$\frac{d^2}{d\mu^2} \log f(x, \mu) = \frac{d^2}{d\mu^2} \left[ -\log(2\pi) - \frac{(x-\mu)^2}{2} \right] = -1.$$

On considère l'estimateur  $T_n(\mathbf{X}) = \bar{X}_n$  de  $\mu$ . On a que  $g(\mu) = \mu$  est  $C^1(\mathbb{R})$ ,  $g'(\mu) = 1$  et que

$$\begin{aligned} \int T(\mathbf{x}) \frac{\partial}{\partial \mu} p(\mathbf{x}, \mu) d\mathbf{x} &= \frac{1}{n} \sum_{i=1}^n \int x_i \frac{\partial}{\partial \mu} e^{-\frac{1}{2} \sum_{j=1}^n (x_j - \mu)^2} \frac{d\mathbf{x}}{(2\pi)^{n/2}} \\ &= \frac{1}{n} \sum_{i=1}^n \sum_{k=1}^n \int x_i (x_k - \mu) e^{-\frac{1}{2} \sum_{j=1}^n (x_j - \mu)^2} \frac{d\mathbf{x}}{(2\pi)^{n/2}} \\ &= \frac{1}{n} \sum_{i=1}^n \int x_i (x_i - \mu) e^{-\frac{1}{2} \sum_{j=1}^n (x_j - \mu)^2} \frac{d\mathbf{x}}{(2\pi)^{n/2}} \\ &= \frac{1}{n} \sum_{i=1}^n \int (x_i - \mu)^2 e^{-\frac{1}{2} \sum_{j=1}^n (x_j - \mu)^2} \frac{d\mathbf{x}}{(2\pi)^{n/2}} = 1. \end{aligned}$$

Toutes les hypothèses du Théorème 41 sont satisfaites donc la borne de Cramer-Rao est valable

$$\text{Var}(T_n) \geq \frac{g'(\mu)^2}{n I(\mu)} = \frac{1}{n}.$$

D'autre part on a aussi par un calcul direct que  $\text{Var}(T_n) = 1/n$  donc l'estimateur  $T_n(\mathbf{X})$  est uniformément efficace.

**Théorème 44.** *Dans les mêmes conditions du Théorème 41 on a que l'estimateur  $T_n(\mathbf{X})$  est uniformément efficace ssi existe une fonction déterministe  $a_n(\theta)$  telle que*

$$\sum_{i=1}^n S(X_i, \theta) = a_n(\theta)(T_n(\mathbf{X}) - g(\theta)).$$

**Exemple 45.**  $X \sim \mathcal{N}(\mu, 1)$ ,  $T_n(\mathbf{X}) = \bar{X}_n$ ,  $g(\mu) = \mu$ .

$$S(x, \mu) = \frac{d}{d\mu} \log f(x, \mu) = x - \mu.$$

$$\sum_{i=1}^n S(X_i, \mu) = \sum_{i=1}^n (X_i - \mu) = n(\bar{X}_n - \mu) = n(T_n(\mathbf{X}) - g(\mu))$$

et en prenant  $a_n(\mu) = n$  le théorème précédent est valable. Il n'est donc pas surprenante que l'estimateur  $T_n$  soit efficace.

## Lien entre l'information de Fisher et la loi asymptotique de l'EMV

On suppose ici  $d = 1$ .

**Théorème 46.** *(cas discret) Soit  $\mathcal{P} = \{P_\theta : \theta \in \Theta\}$  un modèle paramétrique vérifiant les hypothèses **H1**, **H2**, **H3** tel que  $0 < I(\theta) < +\infty$ . On suppose que l'EMV  $\hat{\theta}_n$  existe et est unique. Soit  $\theta_0$  la vraie valeur du paramètre  $\theta$  inconnu. Si existe  $\delta > 0$  et  $k(x) \geq 0$  tels que*

$$i. \left| \frac{d^2}{d\theta^2} \log p(x, \theta) \right| \leq k(x) \quad \text{pour tout } \theta \in [\theta_0 - \delta, \theta_0 + \delta]$$

ii.  $\mathbb{E}_{\theta_0}[k(X)] < +\infty$

alors

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1/I(\theta_0)).$$

**Remarque 47.** Dans le cas continu remplacer  $p(x, \theta)$  par  $f(x, \theta)$  dans l'énoncé précédente.

**Exemple 48.** Soit  $X \sim \mathcal{E}(\lambda)$ ,  $\lambda > 0$ .  $\Theta = ]0, +\infty[$ .

$$f(x, \lambda) = \lambda e^{-\lambda x} \mathbb{I}_{x>0}$$

$$r = 1, h(x) = \mathbb{I}_{x>0}, c(\lambda) = \lambda, \alpha_1(\lambda) = -\lambda \in C^2(\Theta), \Gamma_1(x) = x$$

$\Rightarrow$  le modèle satisfait **H1**, **H2**, **H3**.

$$S(x, \lambda) = \frac{1}{\lambda} - x$$

$$I(\lambda) = \mathbb{E}_\lambda[(\lambda^{-1} - X)^2] = \lambda^{-2} \in ]0, +\infty[.$$

L'EMV de  $\lambda$  est  $\hat{\lambda}_n = 1/\bar{X}_n$  (existe et est unique).

Soit  $\delta > 0$  assez petit tel que  $]\lambda_0 - \delta, \lambda_0 + \delta[ \subset ]0, +\infty[$ . ( $\lambda_0$  est le vrai valeur inconnu de  $\lambda$ ).

$$\frac{d^2}{d\lambda^2} \log f(x, \lambda) = -\frac{1}{\lambda^2}$$

$$\left| \frac{d^2}{d\lambda^2} \log f(x, \lambda) \right| = \frac{1}{\lambda^2} \leq \frac{1}{(\lambda_0 - \delta)^2} = k(x)$$

On a que  $k(x) \geq 0$  et que  $k(X)$  est intégrable. D'après le théorème précédente on obtient que

$$\sqrt{n}((\bar{X}_n)^{-1} - \lambda_0) = \sqrt{n}(\hat{\lambda}_n - \lambda_0) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \lambda_0^2).$$

Directement on aurait pu raisonner comme suivre: par le TCL on a

$$\sqrt{n}(\bar{X}_n - \lambda_0^{-1}) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \lambda_0^{-2})$$

On pose  $g(x) = 1/x$  définie sur  $]0, +\infty[$ . La fonction  $g$  est  $C^1$  dans un voisinage de  $\lambda_0 > 0$ . D'après la  $\delta$ -méthode

$$\sqrt{n}(g(\bar{X}_n) - g(\lambda_0^{-1})) \xrightarrow{\mathcal{L}} \mathcal{N}(0, (g'(1/\lambda_0))^2 \lambda_0^{-2})$$

$$g'(x) = -1/x^2$$

$$(g'(1/\lambda_0))^2 \lambda_0^{-2} = \lambda_0^2$$

et on retrouve que

$$\sqrt{n}((\bar{X}_n)^{-1} - \lambda_0) = \sqrt{n}(g(\bar{X}_n) - g(\lambda_0^{-1})) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \lambda_0^2).$$