

MAP 311 - Aléatoire

Leçon 7

2016-2017

Rappel : Théorème de la limite centrale

Théorème

Soit $(X_n)_{n \in \mathbb{N}^*}$ une suite de variables aléatoires réelles indépendantes et de même loi, d'espérance m et de variance $\sigma^2 > 0$.

- La suite $\sqrt{n}(\frac{1}{n} \sum_{i=1}^n X_i - m)_{n \in \mathbb{N}^*}$ converge en loi vers une variable aléatoire de loi $\mathcal{N}(0, \sigma^2)$.
- Pour tous $a \leq b$,

$$\lim_{n \rightarrow +\infty} \mathbb{P}\left(a \leq \frac{\sqrt{n}}{\sigma} \left(\frac{1}{n} \sum_{i=1}^n X_i - m\right) \leq b\right) = \frac{1}{\sqrt{2\pi}} \int_a^b \exp\left(-\frac{x^2}{2}\right) dx$$

Méthode Delta

Soit $(X_n)_{n \in \mathbb{N}}$ une suite de variables aléatoires i.i.d., d'espérance m et de variance σ^2 . On note

$$\bar{X}_n = \frac{\sum_{i=1}^n X_i}{n}$$

On connaît le comportement de \bar{X}_n quand $n \rightarrow +\infty$.

Peut-on en déduire le comportement de $g(\bar{X}_n)$?

Proposition

- Pour toute fonction continue g , $g(\bar{X}_n) \xrightarrow{n \rightarrow +\infty} g(m)$ p.s.
- Pour toute fonction g de classe \mathcal{C}^1 ,

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

- Si $g'(m) = 0$ et g est de classe \mathcal{C}^2 , alors

$$n(g(\bar{X}_n) - g(m)) \xrightarrow{\mathcal{L}} \frac{1}{2} \sigma^2 g''(m) \chi_1^2$$

Exemple : Soit $(X_n)_{n \in \mathbb{N}}$ une suite de v.a. i.i.d. de loi de Bernoulli de paramètre $p \in]0, 1[$.

Quel est le comportement asymptotique de $T_n = \bar{X}_n(1 - \bar{X}_n)$?

On applique la méthode Delta avec $g(x) = x(1 - x)$. On a $g'(x) = 1 - 2x$.
Si $p \neq 1/2$, $g'(p) \neq 0$ et on a alors

$$\sqrt{n}(T_n - p(1 - p)) \xrightarrow{\mathcal{L}} \mathcal{N}(0, p(1 - p)(1 - 2p)^2)$$

Si $p = 1/2$, $g'(1/2) = 0$ et $g''(1/2) = -2$. On applique la dernière partie de la proposition :

$$n(T_n - \frac{1}{4}) \xrightarrow{\mathcal{L}} -\frac{1}{4}\chi_1^2$$

Preuve de la méthode Delta.

- Si g de classe \mathcal{C}^1 .

Formule des accroissements finis : Pour chaque n ,

$$g(\bar{X}_n) = g(m) + g'(\theta_n)(\bar{X}_n - m)$$

où θ_n se trouve entre m et \bar{X}_n .

Par la loi des grands nombres, $(\bar{X}_n)_n$ converge p.s. vers m et donc il en est de même pour $(\theta_n)_n$. Comme g est de classe \mathcal{C}^1 , la suite $(g'(\theta_n))_n$ converge p.s. vers $g'(m)$. Or

$$\sqrt{n}(g(\bar{X}_n) - g(m)) = \sqrt{n}(\bar{X}_n - m)g'(\theta_n)$$

Par le TCL, $\sqrt{n}(\bar{X}_n - m)$ converge en loi vers $\mathcal{N}(0, \sigma^2)$. Comme $(g'(\theta_n))_n$ converge p.s. vers $g'(m)$, donc en probabilité, on peut appliquer le théorème de Slutsky.

- Si $g'(m) = 0$ et g de classe \mathcal{C}^2 .

Par la formule de Taylor-Lagrange :

$$g(\bar{X}_n) = g(m) + g'(m)(\bar{X}_n - m) + \frac{1}{2}g''(\theta_n)(\bar{X}_n - m)^2,$$

où θ_n se trouve entre m et \bar{X}_n .

Par le TCL, $\sqrt{n}(\bar{X}_n - m)$ converge en loi vers $\mathcal{N}(0, \sigma^2)$ et donc

$$n(\bar{X}_n - m)^2 \xrightarrow{\mathcal{L}} \sigma^2 \chi_1^2$$

Comme précédemment, $(\theta_n)_n$ converge p.s. vers m et par continuité $(g''(\theta_n))_n$ converge p.s. vers $g''(m)$.

Par le théorème de Slutsky, on conclut que

$$n(g(\bar{X}_n) - g(m)) = \frac{1}{2}g''(\theta_n)n(\bar{X}_n - m)^2 \xrightarrow{\mathcal{L}} \frac{1}{2}g''(m)\sigma^2 \chi_1^2$$

TCL multi-dimensionnel

Soit $(\mathbf{X}_n)_{n \in \mathbb{N}}$ une suite de vecteurs aléatoires indépendants à valeurs dans \mathbb{R}^d , de même loi, avec $\mathbf{m} = \mathbb{E}(\mathbf{X}_1)$ et \mathbf{C}_X la matrice de covariance de \mathbf{X}_1 .

Théorème

Les vecteurs aléatoires

$$\sqrt{n} \left(\frac{1}{n} \sum_{i=1}^n \mathbf{X}_i - \mathbf{m} \right)$$

convergent en loi vers un vecteur aléatoire gaussien centré de matrice de covariance \mathbf{C}_X .

La vitesse de convergence de $\frac{1}{n} \sum_{i=1}^n \mathbf{X}_i$ vers \mathbf{m} est toujours en $1/\sqrt{n}$, indépendante de la dimension d .

Exemple : Soit $(X_n)_n$ des variables aléatoires réelles i.i.d. centrées réduites. Soit $S_n = \sum_{i=1}^n X_i$. On sait que S_n/\sqrt{n} converge en loi. Montrons que S_n/\sqrt{n} ne peut pas converger en probabilité.

Si c'était le cas, la suite $(S_{2n}/\sqrt{2n} - S_n/\sqrt{n})_n$ devrait tendre en probabilité, et donc en loi, vers 0.

Or

$$\frac{S_{2n}}{\sqrt{2n}} - \frac{S_n}{\sqrt{n}} = \frac{1}{\sqrt{2n}} \sum_{i=1}^{2n} X_i - \frac{1}{\sqrt{n}} \sum_{i=1}^n X_i = \frac{1-\sqrt{2}}{\sqrt{2n}} \sum_{i=1}^n X_i + \frac{1}{\sqrt{2n}} \sum_{i=n+1}^{2n} X_i$$

On a (en introduisant une autre suite i.i.d. X'_i de même loi que X_i)

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n \begin{pmatrix} X_i \\ X'_i \end{pmatrix} \xrightarrow{\mathcal{L}} \mathcal{N}\left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \right)$$

Donc

$$\frac{S_{2n}}{\sqrt{2n}} - \frac{S_n}{\sqrt{n}} \stackrel{\text{en loi}}{=} \frac{1-\sqrt{2}}{\sqrt{2}} \frac{1}{\sqrt{n}} \sum_{i=1}^n X_i + \frac{1}{\sqrt{2}} \frac{1}{\sqrt{n}} \sum_{i=1}^n X'_i \xrightarrow{\mathcal{L}} \mathcal{N}(0, \sigma^2)$$

avec $\sigma^2 = \left(\frac{1-\sqrt{2}}{\sqrt{2}}\right)^2 + \left(\frac{1}{\sqrt{2}}\right)^2$.

Statistique

Science des données.

Un statisticien travaille sur des données (résultats d'un sondage, données météorologiques,...) pour :

- 1 effectuer une prévision (exemple : résultat d'une élection qui aura lieu prochainement à partir d'un sondage),
- 2 quantifier la certitude liée à une prévision (exemple : fourchette dans le cas d'un sondage),
- 3 répondre à une question comme "le candidat X sera-t-il élu ?", "le réchauffement climatique est-il réel ?", pour aider à la prise de décision.

Réponses :

- 1 estimation statistique,
- 2 théorie des intervalles (ou des régions) de confiance,
- 3 tests de décision.

Estimation statistique

On observe des réalisations d'un phénomène aléatoire (sexe d'un nouveau-né, température journalière, ...) qu'on appelle observations. Ces observations sont des copies i.i.d. d'une loi **inconnue** qu'on cherche à retrouver.

Exemple 1 : On observe les sexes de n nouveaux-nés dans une maternité. Le sexe, fille (F) ou garçon (G), d'un nouveau-né est modélisé par une loi P_θ sur $\{F, G\}$ de paramètre inconnu $\theta \in [0, 1]$, avec $P_\theta(\{G\}) = \theta$ et $P_\theta(\{F\}) = 1 - \theta$.

On souhaite connaître la proportion de garçons à la naissance. Ceci revient à chercher à estimer θ .

Morale :

En probabilités : on se donne une loi P et on cherche les propriétés d'une suite i.i.d. de loi P .

En statistique : on observe une suite i.i.d. et on cherche la loi.

Modèle statistique

Définition

Un modèle statistique est un triplet $(\mathcal{X}, \mathcal{A}, \mathcal{P})$ où \mathcal{X} est l'espace fondamental (l'ensemble des valeurs possibles des observations), \mathcal{A} est une tribu sur \mathcal{X} , et \mathcal{P} est une **famille** de probabilités sur $(\mathcal{X}, \mathcal{A})$.

Un modèle statistique est dit paramétrique s'il existe un entier p et un ensemble $\Theta \subset \mathbb{R}^p$ tels que \mathcal{P} s'écrit sous la forme :

$$\mathcal{P} = \{P_\theta, \theta \in \Theta\},$$

où, pour tout $\theta \in \Theta$, P_θ est une probabilité sur $(\mathcal{X}, \mathcal{A})$.

Exemple 1 : Le modèle statistique est $(\{F, G\}, \mathcal{P}(\{F, G\}), \mathcal{P})$ où :

$$\mathcal{P} = \{P_\theta, \theta \in [0, 1]\},$$

et $P_\theta(\{F\}) = 1 - \theta$ et $P_\theta(\{G\}) = \theta$. Ici $\Theta = [0, 1]$.

Observations

Définition

Un n -échantillon est un vecteur aléatoire $\mathbf{X} = (X_i)_{i=1, \dots, n}$ de n v.a. i.i.d. de même loi qui appartient au modèle statistique.

On observe un n -échantillon \mathbf{X} de loi P_θ (θ inconnu).

On cherche une quantité $f(\mathbf{X})$ qui s'approche du paramètre inconnu θ .

Une telle quantité est appelée estimateur de θ et est souvent notée $\hat{\theta}_n$.

Un estimateur = une fonction déterministe $f : \mathcal{X}^n \rightarrow \Theta$.

Exemple 1 : On a $X_i = G$ si la $i^{\text{ème}}$ naissance donne un garçon, et $X_i = F$ si c'est une fille. (X_1, \dots, X_n) est un n -échantillon de la loi P_θ .

Un estimateur de θ est la proportion empirique de garçons :

$$\hat{\theta}_n = \frac{\text{Card}(i = 1, \dots, n, X_i = G)}{n} = \frac{1}{n} \sum_{i=1}^n \mathbf{1}_G(X_i).$$

On a $\hat{\theta}_n = f(X_1, \dots, X_n)$, avec $f(x_1, \dots, x_n) = (1/n) \sum_{i=1}^n \mathbf{1}_G(x_i)$.

Exemple 2 : L'autonomie d'une batterie de téléphone portable est modélisée par une loi exponentielle de paramètre $\lambda \in]0, +\infty[$. Pour estimer λ , on laisse marcher n téléphones jusqu'à ce qu'ils s'éteignent, on observe donc n durées, à partir desquelles on essaye d'estimer λ .

- Le modèle statistique est $(\mathbb{R}, \mathcal{B}(\mathbb{R}), \mathcal{P})$ où

$$\mathcal{P} = \{P_\lambda, \lambda > 0\},$$

et P_λ est la probabilité sur $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ de densité $p_\lambda(x) = \lambda e^{-\lambda x} \mathbf{1}_{]0, +\infty[}(x)$.

- On cherche un estimateur de λ .

- Estimateur naturel : on sait que

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

est proche de l'espérance $\mathbb{E}_\lambda(X_1) = 1/\lambda$ d'après la Loi Forte des Grands Nombres. On peut donc proposer comme estimateur de λ :

$$\hat{\lambda}_n = f(\mathbf{X}) \text{ avec } f(\mathbf{x}) = \left(\frac{1}{n} \sum_{i=1}^n x_i \right)^{-1}$$

- Cependant, on pourrait s'y prendre autrement. En notant

$$\check{\lambda}_n = \check{f}(\mathbf{X}) \text{ avec } \check{f}(\mathbf{x}) = \left(\frac{1}{2n} \sum_{i=1}^n x_i^2 \right)^{-1/2},$$

on sait aussi que $\check{\lambda}_n$ est proche de $(\frac{1}{2}\mathbb{E}_\lambda(X_1^2))^{-1/2} = \lambda$ d'après la LFGN.

- Ceci montre que $\hat{\lambda}_n$ et $\check{\lambda}_n$ sont tous les deux susceptibles de nous donner une estimation raisonnable de λ (lorsque n est grand).

Qualités d'un estimateur : convergence

On examine les qualités d'une suite d'estimateurs $(\hat{\theta}_n)_{n \in \mathbb{N}^*}$ définie par une suite de fonctions $f_n : \mathcal{X}^n \rightarrow \Theta$.

Exemple 1 : On examine la suite $\hat{\theta}_n = f_n(X_1, \dots, X_n)$ définie par :

$$f_n : \begin{cases} \{F, G\}^n \rightarrow \mathbb{R}, \\ (x_1, \dots, x_n) \mapsto \frac{1}{n} \sum_{i=1}^n \mathbf{1}_G(x_i). \end{cases}$$

Sous \mathbb{P}_θ , les X_i sont i.i.d. de loi P_θ .

Définition (Convergence)

On dit que $\hat{\theta}_n$ est convergent si, pour tout $\theta \in \Theta$:

$$\mathbb{P}_\theta \left(\hat{\theta}_n \xrightarrow{n \rightarrow +\infty} \theta \right) = 1.$$

Exemple 1 : Sous \mathbb{P}_θ , les v.a. $\mathbf{1}_G(X_i)$ sont i.i.d. de loi de Bernoulli de paramètre θ . Par la loi forte des grands nombres :

$$\mathbb{P}_\theta \left(\lim_{n \rightarrow +\infty} \hat{\theta}_n = \theta \right) = \mathbb{P}_\theta \left(\lim_{n \rightarrow +\infty} \frac{1}{n} \sum_{j=1}^n \mathbf{1}_G(X_j) = \theta \right) = 1.$$

Qualités d'un estimateur : biais

Définition (Biais)

Un estimateur est non-biaisé si $\mathbb{E}_\theta(\hat{\theta}_n) = \theta$ pour tout $\theta \in \Theta$ et pour tout $n \in \mathbb{N}^$.*

Exemple 1 :

$$\mathbb{E}_\theta(\hat{\theta}_n) = \frac{1}{n} \sum_{j=1}^n \mathbb{E}_\theta(\mathbf{1}_G(X_j)) = \mathbb{E}_\theta(\mathbf{1}_G(X_1)) = \theta.$$

L'estimateur $\hat{\theta}_n$ est donc non-biaisé.

Qualités d'un estimateur : risque quadratique moyen

Définition (Risque quadratique moyen)

Si $g : \Theta \rightarrow \mathbb{R}$, alors le risque quadratique moyen d'un estimateur \hat{g}_n de $g(\theta)$ est la moyenne quadratique des écarts à la valeur à estimer :

$$\text{RQM}_\theta(\hat{g}_n) = \mathbb{E}_\theta [(\hat{g}_n - g(\theta))^2] .$$

Le risque quadratique moyen se décompose en une partie “variance” et une partie “biais” :

$$\text{RQM}_\theta(\hat{g}_n) = \text{Var}_\theta(\hat{g}_n) + (\mathbb{E}_\theta(\hat{g}_n) - g(\theta))^2 .$$

Un “bon” estimateur a un RQM “petit”.

Exemple 1 :

$$\text{RQM}_\theta(\hat{\theta}_n) = \text{Var}_\theta(\hat{\theta}_n) = \frac{1}{n} \text{Var}_\theta(\mathbf{1}_G(X_1)) = \frac{\theta(1-\theta)}{n} .$$

Qualités d'un estimateur : normalité asymptotique

Définition (Normalité asymptotique)

Soit $g : \Theta \rightarrow \mathbb{R}$. Un estimateur \hat{g}_n de $g(\theta)$ est dit asymptotiquement normal s'il existe deux fonctions $m_n(\theta)$ et $\sigma_n(\theta)$ telles que, sous \mathbb{P}_θ , la suite de variables aléatoires $(\hat{g}_n - m_n(\theta))/\sigma_n(\theta)$ converge en loi quand $n \rightarrow +\infty$ vers une loi gaussienne centrée réduite.

Très souvent, mais pas toujours, $m_n(\theta) = g(\theta)$ et $\sigma_n(\theta) = \sigma(\theta)/\sqrt{n}$ pour une fonction $\sigma^2(\theta)$ qu'on appelle variance asymptotique.

Exemple 1 : Par le théorème de la limite centrale, sous \mathbb{P}_θ :

$$\sqrt{n}(\hat{\theta}_n - \theta) = \sqrt{n}\left(\frac{1}{n} \sum_{j=1}^n \mathbf{1}_G(X_j) - \theta\right) \xrightarrow{n \rightarrow +\infty} \mathcal{N}(0, \theta(1 - \theta)),$$

en loi. La variance asymptotique est ici $\sigma^2(\theta) = \theta(1 - \theta)$.

Estimateurs empiriques

On considère un modèle statistique de la forme $(\mathbb{R}, \mathcal{B}(\mathbb{R}), \mathcal{P})$.

Il arrive souvent que le modèle statistique soit paramétré par la moyenne et/ou la variance de la loi inconnue.

Exemple : modèle gaussien :

$$\mathcal{P} = \{ \mathcal{N}(\mu, \sigma^2), \mu \in \mathbb{R}, \sigma^2 \in]0, +\infty[\}.$$

Proposition (Estimateur de la moyenne)

Soit $(X_i)_{i=1, \dots, n}$ un n -échantillon d'un modèle statistique $(\mathbb{R}, \mathcal{B}(\mathbb{R}), \mathcal{P})$ dont les lois sont intégrables.

La moyenne (l'espérance) d'une v.a. de loi P_θ est notée μ_θ .

La moyenne empirique \bar{X}_n définie par :

$$\bar{X}_n = \frac{1}{n} \sum_{j=1}^n X_j,$$

est un estimateur de la moyenne.

Proposition (Estimateur de la moyenne - suite)

La moyenne empirique \bar{X}_n définie par :

$$\bar{X}_n = \frac{1}{n} \sum_{j=1}^n X_j,$$

est un estimateur de la moyenne tel que :

(i) \bar{X}_n est non-biaisé.

(ii) \bar{X}_n est convergent.

(iii) Si de plus les lois sont de carré intégrable, alors $\text{RQM}_\theta(\bar{X}_n) = \sigma_\theta^2/n$, avec σ_θ^2 la variance de la loi P_θ et \bar{X}_n est asymptotiquement normal, avec

$$\sqrt{n}(\bar{X}_n - \mu_\theta) \xrightarrow{n \rightarrow \infty} \mathcal{N}(0, \sigma_\theta^2) \text{ en loi}$$

Proposition (Estimateur de la variance)

Soit $(X_i)_{i=1, \dots, n}$ un n -échantillon d'un modèle statistique $(\mathbb{R}, \mathcal{B}(\mathbb{R}), \mathcal{P})$ dont les lois sont de carré intégrable.

La variance d'une v.a. de loi P_θ est notée σ_θ^2 .

La variance empirique de l'échantillon est définie par :

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

Cet estimateur de la variance vérifie les propriétés suivantes.

(i) L'estimateur est biaisé :

$$\mathbb{E}_\theta(\bar{V}_n) = \frac{n-1}{n} \sigma_\theta^2$$

Preuve :
$$\bar{V}_n = \frac{1}{n} \sum_{j=1}^n X_j^2 - \left(\frac{1}{n} \sum_{j=1}^n X_j \right)^2 = \frac{1}{n} \sum_{j=1}^n X_j^2 - \frac{1}{n^2} \sum_{i,j=1}^n X_i X_j.$$

$$\mathbb{E}(\bar{V}_n) = \mathbb{E}(X^2) - \frac{1}{n} \mathbb{E}(X^2) - \frac{n-1}{n} \mathbb{E}(X)^2 = \frac{n-1}{n} (\mathbb{E}(X^2) - \mathbb{E}(X)^2)$$

Proposition (Estimateur de la variance - suite)

(ii) *L'estimateur est convergent.*

(iii) *Si les lois sont de quatrième moment fini, alors :*

$$\text{RQM}_{\theta}(\bar{V}_n) = \frac{\mu_{\theta}^{(4)} - \sigma_{\theta}^4}{n} + O\left(\frac{1}{n^2}\right),$$

où $\mu_{\theta}^{(4)} = \mathbb{E}_{\theta}((X_1 - \mathbb{E}_{\theta}(X_1))^4)$ et \bar{V}_n est asymptotiquement normal :

$$\sqrt{n}(\bar{V}_n - \sigma_{\theta}^2) \xrightarrow{n \rightarrow +\infty} \mathcal{N}(0, \mu_{\theta}^{(4)} - \sigma_{\theta}^4) \text{ en loi}$$

Proposition (Variance empirique non-biaisée)

La variance empirique non-biaisée V_n est définie par :

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

Cet estimateur de la variance vérifie les propriétés suivantes.

(i) V_n est non-biaisé : pour tout $n \geq 2$, $\mathbb{E}_\theta(V_n) = \sigma_\theta^2$.

(ii) V_n est convergent.

(iii) Si les lois sont de quatrième moment fini, alors :

$$\text{RQM}_\theta(V_n) = \frac{\mu_\theta^{(4)} - \sigma_\theta^4}{n} + O\left(\frac{1}{n^2}\right),$$

et V_n est asymptotiquement normal :

$$\sqrt{n}(V_n - \sigma_\theta^2) \xrightarrow{n \rightarrow +\infty} \mathcal{N}(0, \mu_\theta^{(4)} - \sigma_\theta^4) \text{ en loi}$$

Méthode des moments

Soit $(X_i)_{i=1,\dots,n}$ un n -échantillon d'un modèle $\mathcal{P} = \{P_\theta, \theta \in \Theta\}$. On cherche un estimateur de θ .

Supposons : On a trouvé une fonction $g : \Theta \rightarrow \Theta' \subset \mathbb{R}^d$ inversible et de fonction réciproque continue et une fonction $\psi : \mathcal{X} \rightarrow \mathbb{R}^d$ telle que $\mathbb{E}_\theta(|\psi(X_1)|) < \infty$ pour tout $\theta \in \Theta$ et

$$g(\theta) = \mathbb{E}_\theta(\psi(X_1)).$$

Résultat : L'estimateur des moments

$$\hat{\theta}_n = g^{-1}\left(\frac{1}{n} \sum_{i=1}^n \psi(X_i)\right).$$

est convergent.

En effet, $\frac{1}{n} \sum_{i=1}^n \psi(X_i)$ est un estimateur convergent de $g(\theta) = \mathbb{E}_\theta(\psi(X_1))$ d'après la Loi Forte des Grands Nombres, et g^{-1} est continue.

Exemple : On considère le modèle uniforme $\mathcal{P} = \{P_\theta, \theta \in]0, +\infty[\}$, où P_θ est la loi uniforme sur $[0, \theta]$. Si X_1 a pour loi P_θ , alors on a :

$$\mathbb{E}_\theta(X_1) = \frac{\theta}{2}.$$

Par conséquent, si $(X_i)_{i=1, \dots, n}$ est un n -échantillon de loi P_θ , alors

$$\hat{\theta}_n = \frac{2}{n} \sum_{i=1}^n X_i$$

est un estimateur de θ .

Cet estimateur est non-biaisé, convergent, son RQM est

$$\text{RQM}_\theta(\hat{\theta}_n) = \text{Var}_\theta(\hat{\theta}_n) = \frac{4}{n} \text{Var}_\theta(X_1) = \frac{\theta^2}{3n},$$

et il est asymptotiquement normal :

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{n \rightarrow +\infty} \mathcal{N}(0, \theta^2/3) \text{ en loi.}$$

Estimation par maximum de vraisemblance

On considère un modèle statistique $\mathcal{P} = \{P_\theta, \theta \in \Theta\}$ tel que :

- ou bien \mathcal{X} est fini ou dénombrable et pour tout $\theta \in \Theta$, la loi P_θ est discrète et à valeurs dans \mathcal{X} . On pose alors $p(x, \theta) = P_\theta(\{x\})$ pour tout $x \in \mathcal{X}$. On pose pour tout $\mathbf{x} = (x_1, \dots, x_n) \in \mathcal{X}^n$:

$$p_n(\mathbf{x}, \theta) = p(x_1, \theta) \cdots p(x_n, \theta),$$

qu'on appelle vraisemblance.

- ou bien $\mathcal{X} = \mathbb{R}$ ou \mathbb{R}^d et pour tout $\theta \in \Theta$, la loi P_θ est à densité. On note alors $p(x, \theta)$ la densité de la loi P_θ et $p_n(\mathbf{x}, \theta)$ la densité jointe d'un n -échantillon, qu'on appelle vraisemblance.

Définition

On suppose que pour toute réalisation $\mathbf{x} = (x_1, \dots, x_n)$ d'un n -échantillon $\mathbf{X} = (X_1, \dots, X_n)$, il existe une unique valeur $\theta_n(\mathbf{x}) \in \Theta$ qui maximise la vraisemblance (vue comme fonction de θ) :

$$\theta_n(\mathbf{x}) = \operatorname{argmax}_{\theta \in \Theta} p_n(\mathbf{x}, \theta).$$

Alors l'estimateur $\hat{\theta}_n = \theta_n(\mathbf{X})$ est appelé *Estimateur du Maximum de Vraisemblance (EMV)* de θ .

- Un tel estimateur n'existe pas toujours et il peut être multiple. Cependant dans la plupart des cas, cet estimateur existe, est unique, facile à calculer, et possède de bonnes propriétés.
- Parfois il est plus facile de chercher $\theta_n(\mathbf{x}) = \operatorname{argmax}_{\theta \in \Theta} \ln(p_n(\mathbf{x}, \theta))$
- En pratique, on cherche souvent l'EMV, puis on étudie ses propriétés.

Interprétation bayésienne : Supposons que \mathcal{X} et Θ sont finis.

Avant de recueillir des données, on ne sait rien sur le paramètre θ , à part qu'il est dans Θ , donc on peut considérer que c'est une réalisation d'une variable aléatoire discrète T de loi uniforme sur Θ .

La loi jointe des données et du paramètre est donc :

$$P(\mathbf{x}, \theta) := \mathbb{P}(\mathbf{X} = \mathbf{x}, T = \theta) = \mathbb{P}_\theta(\mathbf{X} = \mathbf{x})\mathbb{P}(T = \theta) = p_n(\mathbf{x}, \theta) \frac{1}{\text{card}(\Theta)}.$$

La loi du paramètre sachant les données est :

$$P(\theta|\mathbf{x}) := \mathbb{P}(T = \theta|\mathbf{X} = \mathbf{x}) = \frac{P(\mathbf{x}, \theta)}{P(\mathbf{x})}, \text{ avec } P(\mathbf{x}) = \sum_{\theta' \in \Theta} P(\mathbf{x}, \theta'),$$

ce qui s'écrit donc :

$$P(\theta|\mathbf{x}) = \frac{p_n(\mathbf{x}, \theta)}{\text{card}(\Theta)P(\mathbf{x})}.$$

Le mode de cette loi, i.e. le paramètre θ le plus probable dans Θ sachant les données \mathbf{x} , est l'élément de Θ qui maximise $P(\theta|\mathbf{x})$, qui est aussi celui qui maximise $p_n(\mathbf{x}, \theta)$: c'est donc l'EMV.

Exemple : Dans le modèle de Bernoulli, $\mathcal{X} = \{0, 1\}$,

$$\mathcal{P} = \{\mathcal{B}(\theta), \theta \in [0, 1]\},$$

la vraisemblance est :

$$\begin{aligned} p_n(\mathbf{x}, \theta) &= \prod_{i=1}^n \theta^{1_{\{x_i=1\}}} (1 - \theta)^{1_{\{x_i=0\}}} \\ &= [\theta^{\bar{x}_n} (1 - \theta)^{1 - \bar{x}_n}]^n, \end{aligned}$$

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

A \mathbf{x} fixé, en tant que fonction de θ , la vraisemblance est maximale lorsque la fonction $\theta \mapsto \theta^{\bar{x}_n} (1 - \theta)^{1 - \bar{x}_n}$ est maximale. Le maximum sur $[0, 1]$ est unique et est atteint au point où la dérivée s'annule, en $\theta = \bar{x}_n$.

L'EMV est ici l'estimateur empirique.

EMV pour les lois gaussiennes

Etant donnés des paramètres μ, σ^2 , le vecteur aléatoire (X_1, \dots, X_n) i.i.d. de loi $\mathcal{N}(\mu, \sigma^2)$ a une loi de densité

$$p_n((x_1, \dots, x_n), (\mu, \sigma^2)) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x_i - \mu)^2}{2\sigma^2}\right)$$

L'EMV est défini par :

$$(\hat{\mu}_n, \hat{\sigma}_n^2) = \operatorname{argmax}_{\mu, \sigma^2} p_n((X_1, \dots, X_n), (\mu, \sigma^2))$$

Dans ce cas gaussien, on trouve $\hat{\mu}_n = \bar{X}_n$ et $\hat{\sigma}_n^2 = \bar{V}_n$ (variance empirique biaisée). C'est l'unique point (μ, σ^2) où les dérivées de $\ln p_n$ s'annulent.

Exemple : On considère le modèle uniforme $\mathcal{P} = \{P_\theta, \theta \in]0, +\infty[\}$, où P_θ est la loi uniforme sur $[0, \theta]$. La vraisemblance d'un n -échantillon est :

$$p_n(\mathbf{x}, \theta) = \theta^{-n} \prod_{i=1}^n \mathbf{1}_{[0, \theta]}(x_i) = \theta^{-n} \mathbf{1}_{[0, +\infty[} \left(\min_{i=1, \dots, n} (x_i) \right) \mathbf{1}_{[0, \theta]} \left(\max_{i=1, \dots, n} (x_i) \right).$$

- La vraisemblance est maximale pour $\theta_n(\mathbf{x}) = \max_{i=1, \dots, n} (x_i)$. L'EMV est donc $\hat{\theta}_n = \max_{i=1, \dots, n} (X_i)$.
- On peut calculer la loi de l'EMV. Sa fonction de répartition est :

$$\mathbb{P}_\theta(\hat{\theta}_n \leq t) = \begin{cases} 1 & \text{si } t \geq \theta, \\ \mathbb{P}_\theta(X_1 \leq t)^n = \left(\frac{t}{\theta}\right)^n & \text{si } 0 \leq t < \theta, \\ 0 & \text{si } t < 0. \end{cases}$$

Donc, sous \mathbb{P}_θ , $\hat{\theta}_n$ est une v.a. à densité :

$$p_{\hat{\theta}_n}(t) = n \frac{t^{n-1}}{\theta^n} \mathbf{1}_{[0, \theta]}(t).$$

- L'EMV est biaisé :

$$\mathbb{E}_\theta(\hat{\theta}_n) = \int_0^\theta t p_{\hat{\theta}_n}(t) dt = \frac{n\theta}{n+1} = \theta - \frac{\theta}{n+1}$$

- La variance de l'EMV est

$$\text{Var}_\theta(\hat{\theta}_n) = \mathbb{E}_\theta(\hat{\theta}_n^2) - \mathbb{E}_\theta(\hat{\theta}_n)^2 = \frac{n}{(n+1)^2(n+2)}\theta^2,$$

qui est d'ordre $1/n^2$. Le RQM est donc d'ordre $1/n^2$ lui aussi :

$$\text{RQM}_\theta(\hat{\theta}_n) = \text{Var}_\theta(\hat{\theta}_n) + (\mathbb{E}_\theta(\hat{\theta}_n) - \theta)^2 = \frac{2}{(n+1)(n+2)}\theta^2$$

→ plus petit que le RQM de l'estimateur empirique !

-

$$\mathbb{P}_\theta(n(\hat{\theta}_n - \theta) \leq t) = \begin{cases} 1 & \text{si } t \geq 0, \\ \left(1 + \frac{t}{n\theta}\right)^n & \text{si } -n\theta \leq t < 0, \\ 0 & \text{si } t < -n\theta, \end{cases}$$

et donc, pour tout $t \geq 0$:

$$\mathbb{P}_\theta(n(\hat{\theta}_n - \theta) \leq -\theta t) \xrightarrow{n \rightarrow +\infty} e^{-t},$$

ce qui montre que

$$n(\hat{\theta}_n - \theta) \xrightarrow{n \rightarrow +\infty} -\theta Z$$

en loi, où Z est une v.a. exponentielle de paramètre 1.

- Les fluctuations de l'EMV sont d'ordre $1/n$ et de loi exponentielle lorsque n est grand. On est donc loin de la normalité asymptotique.
- On peut débiaiser l'EMV en considérant l'estimateur :

$$\tilde{\theta}_n = \frac{n+1}{n} \hat{\theta}_n = \frac{n+1}{n} \max_{i=1, \dots, n} (X_i).$$

L'estimateur $\tilde{\theta}_n$ est non-biaisé, son RQM est :

$$\text{RQM}_{\theta}(\tilde{\theta}_n) = \text{Var}_{\theta}(\tilde{\theta}_n) = \frac{(n+1)^2}{n^2} \text{Var}_{\theta}(\hat{\theta}_n) = \frac{1}{n(n+2)} \theta^2,$$

qui est plus petit que le RQM de $\hat{\theta}_n$, et il satisfait :

$$n(\tilde{\theta}_n - \theta) \xrightarrow[n \rightarrow +\infty]{} -\theta(Z - 1),$$

en loi, où Z est une v.a. exponentielle de paramètre 1. Notez que $\mathbb{E}((Z-1)^2) = 1 < 2 = \mathbb{E}(Z^2)$, ce qui montre que la variance asymptotique de $\tilde{\theta}_n$ est deux fois plus petite que celle de $\hat{\theta}_n$.

- On considère un n -échantillon de loi $\mathcal{U}(0, \theta_0)$ avec $n = 10$ et $\theta_0 = 1,5$:

$$\mathbf{x} = [1,222 \ 1,358 \ 0,190 \ 1,370 \ 0,948 \ 0,146 \ 0,417 \ 0,820 \ 1,436 \ 1,447]$$

L'estimateur empirique est $\check{\theta}_{10} = 2\bar{x}_{10} = 1,872$.

L'EMV non-biaisé est $\tilde{\theta}_{10} = (11/10) \max_i x_i = 1,592$.

- On considère 1000 échantillons et on trace les histogrammes des 1000 estimations :

