

STATISTIQUE ET ESTIMATION L'ESTIMATION

Introduction

Une statistique est la réduction de l'information apportée par un échantillon.

Définition : Soit (E, \mathcal{Z}^n, P) ($\mathcal{Z}^n = \mathbb{R}^n$ ou \mathbb{C}^n) un modèle d'échantillonnage (au sens précédent). On appelle statistique la variable aléatoire $T(X) = T(x_1, \dots, x_n)$ définie sur E^n dans E' par : $x = (x_1, \dots, x_n) \rightarrow T(x) = T(x_1, \dots, x_n)$

Exemple

$$T_1(x_1, \dots, x_n) = \frac{1}{n} \sum_{i=1}^n x_i$$

$$T_2(x_1, \dots, x_n) = \max\{x_1, \dots, x_n\}$$

$$T_3(x_1, \dots, x_n) = \frac{1}{n} \sum_{i=1}^n |x_i|$$

$T_1(X)$ est l'estimateur de la fonction de répartition $F_X(x)$, appelé aussi fonction de répartition empirique $F_n(x) = \hat{F}_n(x)$, $F_n(x)$

et σ est une mesure de l'écart de σ à σ ou une statistique.

Exemple : Soit le modèle d'échantillonnage $(E, \mathcal{B}_E, \{U_{\theta, \sigma}\}, \theta \in \mathbb{R}^2)$ à $U_{\theta, \sigma}$ et la loi uniforme sur $[0, \theta]$, $\theta \in \mathbb{R}_+$

On se donne alors θ par suite on a plusieurs estimateurs :

$$\hat{\theta}_1 = \frac{1}{n} \sum_{i=1}^n X_i \quad (\text{moyenne empirique})$$

$$\hat{\theta}_2 = X_{(n)} = \max\{X_1, \dots, X_n\}$$

$$\hat{\theta}_3 = X_{(n)} + \frac{X_{(n)}}{n} = \frac{(n+1)}{n} X_{(n)}$$

$$\hat{\theta}_4 = X_{(n)} + X_{(n)} \quad (X_{(n)} = \min\{X_1, \dots, X_n\})$$

Deux questions se posent :

Question 1 : comment construire un estimateur

Question 2 : comment comparer ces estimateurs pour choisir le meilleur.

Construction de la statistique

Estimation empirique

Soit (X^1, X^2, \dots, X^n) , $(X^i, i \in \{1, \dots, n\})$ un échantillon d'observations;
 X_1, X_2, \dots, X_n une suite de nos observations de sorte que $X_i = X^i$ pour
quelque $i \in \{1, \dots, n\}$ en notant pour la suite
 $m_1 = X_1$ et $m_2 = X_2$ (le premier et le second de X).

Définition #1

On appelle moyenne empirique la statistique $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$.
C'est donc une estimation de $m_0 = \hat{m}_0 = \bar{X}_n$.

Définition #2

On appelle variance empirique d'un échantillon (X^1, \dots, X^n)
 $S_n^2 = \frac{1}{n} \sum_{i=1}^n X_i^2$ qui est une estimation de variance de $m_2 = \sigma^2$.

On en a pu conclure et puisque $m_2 = E(X^2) = E(X_1^2)$

$$\hat{m}_2 = m_2^{(n)} = m_2^{(n)} = \frac{1}{n} \sum_{i=1}^n X_i^2 = S_n^2$$

$$\hat{m}_0 = \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \quad \text{donc } \hat{S}_n^2 = S_n^2$$

Soit \hat{m}_0 donc l'estimation empirique de la variance.

Définition #3

$E_n(\bar{X}_n) = m_0$ (\bar{X}_n est une estimation sans biais de m_0).

$$\text{Var}(\bar{X}_n) = \frac{\sigma^2}{n}$$

Le schéma d'estimation des moments (empiriques) permet
de déduire la fonction de répartition.

$$E_n(f) = f(\bar{X}_n) = \int_{-\infty}^{\infty} f(x) dF_n(x) = \int_{-\infty}^{\infty} f(x) dF_n(x) = E(f(\bar{X}_n))$$

soit $y = f(\bar{X}_n) = f(\frac{1}{n} \sum_{i=1}^n X_i)$ on a alors: puisque $E(f(\bar{X}_n)) = E(y)$

$$E(y) = \frac{1}{n} \sum_{i=1}^n f(\bar{X}_n) = f(\bar{X}_n) = E(f(\bar{X}_n)) = \frac{1}{n} \sum_{i=1}^n f(\bar{X}_n)$$

$$\hat{E}_n(x) = E_n(x) = \frac{1}{n} \sum_{i=1}^n X_i$$

2) Méthode de substitution :

Principe de la méthode :
 Soit on suppose d'un estimateur $\hat{\theta}$ de θ et de $g(\theta)$ et une fonction
 continue avec l'inverse de $g(\theta)$ et $g(\hat{\theta})$:

$$\hat{g}(\theta) = g(\hat{\theta}).$$

Exemple : L'estimateur de l'écart-type σ dérivant S_n^2 et :

$$\hat{\sigma} = S_n \quad \hat{\sigma} = \frac{1}{\sqrt{n}} \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (g(\sigma) = \sigma^2)$$

3) Méthode des moments :

Principe de la méthode :
 Supposons que l'application h définie de $\Theta \subset \mathbb{R}^p$ dans $h(\Theta) \subset \mathbb{R}^p$
 et bijective et continue et soit φ une application de \mathbb{R}^p dans \mathbb{R}^p
 telle que $E(\varphi(X))$ existe et que :

$$h(\theta) = E_{\theta}(\varphi(X)) \quad \text{pour tout } \theta \in \Theta.$$

La méthode des moments consiste à résoudre $\hat{\theta}$ par $\hat{\theta}$:

$$\hat{\theta} = h^{-1}\left(\frac{1}{n} \sum_{i=1}^n \varphi(x_i)\right).$$

En effet :

$$\text{Si } h(\theta) = E_{\theta}(\varphi(X)) \quad \text{alors } \hat{h}(\theta) = E_{\theta}(\varphi(X))$$

On pose $y = \varphi(x)$ et $y_i = \varphi(x_i)$ et comme on a :

$$\hat{E}_{\theta}(y) = \frac{1}{n} \sum_{i=1}^n y_i \quad \text{alors } \hat{h}(\theta) = \frac{1}{n} \sum_{i=1}^n \varphi(x_i)$$

et par la méthode de substitution on sait que $\hat{h}(\theta) = h(\hat{\theta})$

$$\text{donc } h(\hat{\theta}) = \frac{1}{n} \sum_{i=1}^n \varphi(x_i) \quad \text{soit } \hat{\theta} = h^{-1}\left(\frac{1}{n} \sum_{i=1}^n \varphi(x_i)\right)$$

Exemple : Soit X la loi exponentielle de paramètre λ puisque
 $X \sim \mathcal{E}(\lambda)$.

à savoir que $E_{\lambda}(X) = \frac{1}{\lambda}$ donc : $E_{\lambda}(\varphi(X)) = h(\lambda)$ puisque
 d'ici $\varphi(x) = x$ et $h(\lambda) = \frac{1}{\lambda}$ or que $h^{-1}(y) = \frac{1}{y}$.

$$\text{donc } \hat{\lambda} = h^{-1}\left(\frac{1}{n} \sum_{i=1}^n x_i\right) = \frac{1}{\frac{1}{n} \sum_{i=1}^n x_i} = \frac{n}{\sum_{i=1}^n x_i} = \frac{1}{\bar{x}}$$

pour

$(x^0, p_0, \dots, p_n) \in \mathcal{P}$ et $(x^1, p_1, \dots, p_n) \in \mathcal{P}$; et φ et h tels que

$$h(x^0, p_0, \dots, p_n) = (p_0, p_1, \dots, p_n); \quad h(x^1, p_1, \dots, p_n) = (p_1, p_2, \dots, p_n)$$

$$h(x^2, p_2, \dots, p_n) = (p_2, p_3, \dots, p_n); \quad \dots; \quad h(x^{n-1}, p_{n-1}, p_n) = (p_{n-1}, p_n)$$

avec $\varphi(x^0, p_0, \dots, p_n) = (p_0, p_1, \dots, p_n)$ et $\varphi(x^1, p_1, \dots, p_n) = (p_1, p_2, \dots, p_n)$

$$(\hat{p}, \hat{\sigma}^2) = \mathbb{E} \left[\frac{1}{n} \sum_{i=1}^n X_i, \frac{1}{n} \sum_{i=1}^n X_i^2 \right] = \left(\frac{1}{n} \sum_{i=1}^n X_i, \frac{1}{n} \sum_{i=1}^n X_i^2 \right)$$

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n X_i; \quad \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \frac{1}{n} \left(\sum_{i=1}^n X_i \right)^2$$

4) Méthode du maximum de vraisemblance.

Définition 4.1.2

$\mathcal{X} = \{x, \theta, \theta_0, \theta_1, \dots, \theta_n\}$ est un modèle statistique

si \mathcal{X} est un ensemble fini de points (ou un sous-ensemble de \mathbb{R}^n)

l'ensemble \mathcal{O} de maximum de vraisemblance $(\theta_0, \theta_1, \dots, \theta_n)$

est tel que $L(x, \theta) > L(x, \theta')$, $\forall \theta' \in \mathcal{O}$.

Pour le modèle d'échantillonnage on a $L(x, \theta) = \prod_{i=1}^n f(x_i, \theta)$ la densité de l'échantillon.

Si la fonction est concave elle admet au plus un maximum. On détermine le maximum de vraisemblance et obtient le nombre de paramètres dans le cas unidimensionnel, et le gradient dans le cas multidimensionnel.

Remarque: Puisque la fonction logarithme est croissante l'ensemble des θ qui maximisent $L(x, \theta)$ est le même que celui de $\log L(x, \theta)$.

$$\hat{\theta} = \text{Arg max}_{\theta} L(x, \theta) = \text{Arg max}_{\theta} (\log L(x, \theta))$$

Exemple 1:

X est de Bernoulli de paramètre p .

$$f(x) = p^x (1-p)^{1-x}$$

$$L(x_1, \dots, x_n, p) = \prod_{i=1}^n p^{x_i} (1-p)^{1-x_i}$$

$$\log(L(x_1, \dots, x_n, p)) = \sum_{i=1}^n [x_i \log p + (1-x_i) \log(1-p)]$$

$$\psi(p) = \log(L(x_1, \dots, x_n, p)) = \log(p)^{\left(\sum x_i\right)} + \log(1-p)^{\left(\sum (1-x_i)\right)}$$

$$\psi'(p) = \frac{\sum x_i}{p} - \frac{\sum (1-x_i)}{1-p} \quad \text{or} \quad \psi'(p) = -\frac{\sum x_i}{p^2} - \frac{\sum (1-x_i)}{(1-p)^2} < 0$$

$$\psi'(p) = 0 \Leftrightarrow \frac{\sum x_i}{p} - \frac{\sum (1-x_i)}{1-p} = 0$$

$$(1-p) \cdot \sum x_i - p \sum (1-x_i) = 0 \Rightarrow \sum x_i - p \cdot n = 0$$

$$\hat{p} = \frac{1}{n} \sum x_i$$

Exemple 2:

X est de loi normale $\{N(p, \sigma^2), p \in \mathbb{R}, \sigma^2 > 0\}$.

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

$$\log L(p, \sigma^2) = \log(L(x_1, \dots, x_n, (p, \sigma^2))) = -n \log \sigma - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - p)^2$$

$$(1) \quad \frac{\partial \log L(p, \sigma^2)}{\partial p} = \frac{1}{\sigma^2} \sum_{i=1}^n (-2(x_i - p)) = 0$$

$$(2) \quad \frac{\partial \log L(p, \sigma^2)}{\partial \sigma} = -\frac{n}{\sigma} + \frac{1}{\sigma^3} \sum_{i=1}^n (x_i - p)^2 = 0$$

ce qui donne alors:

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n x_i \quad , \quad \hat{\sigma} = \bar{x}_n$$

$$\text{or} \quad \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2 = S_n$$

Proposition: (Invariance de maximum de vraisemblance).

Si θ est un estimateur de maximum de vraisemblance de θ dans un modèle $\{f_{\theta}, \theta \in \Theta\}$, et si g est une application bijective

variable de Θ dans $g(\Theta)$ alors $g(\hat{\theta})$ est bien entendu la
 l'issue de réalisances de $g(\theta)$ sur $\{P_{g(\theta)} | g(\theta) \in g(\Theta)\}$.

l'itération d'un algorithme.

Estimateur convergent

Définition 5.1.1

Un estimateur $\hat{\theta}_n$ de paramètre θ est dit globalement convergent
 constant de $\hat{\theta}_n$ converge en probabilité sur $\{P_{\theta} | \theta \in \Theta\}$ vers θ

$\hat{\theta}_n \xrightarrow{P} \theta$, quel $n \rightarrow \infty$

vers θ , $P(\|\hat{\theta}_n - \theta\| > \epsilon) \rightarrow 0$, $n \rightarrow \infty$ dans le cas unidimensionnel

et $P(\|\hat{\theta}_n - \theta\| > \epsilon) \rightarrow 0$, $n \rightarrow \infty$ dans le cas multidimensionnel

à l'aide de grands nombres:

Si X_1, \dots, X_n est une suite de variables aléatoires indépendantes p. id.

$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ (moyenne empirique) et estimation de μ ($\hat{\mu} = \bar{X}_n$)

1) $\frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{P} \mu$, $n \rightarrow \infty$ (égalité de Bienaymé-Tchebichef)

2) $\hat{\mu} = \bar{X}_n$, $\hat{\mu}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2$ et on a:

3) $\frac{1}{n} \sum_{i=1}^n X_i^2 \xrightarrow{P} E(X^2)$ (égalité de Markov)

4) 1) et 3) on a: $\hat{\mu}^2 = S_n = \frac{1}{n} \sum_{i=1}^n X_i^2 - \left(\frac{1}{n} \sum_{i=1}^n X_i\right)^2$ converge

S_n et donc on obtient l'estimateur convergent de σ^2 .

On a la convergence forte de $\hat{\theta}_n$ vers θ si $\hat{\theta}_n \xrightarrow{a.s.} \theta$, $n \rightarrow \infty$

On a la convergence dans l'échelle de $\hat{\theta}_n$ vers θ , $n \rightarrow \infty$

Estimateur sans biais

Définition 5.1.2: L'estimateur $\hat{\theta}_n$ de θ est dit fonction

pour $\theta \in \Theta$ par: $E_{\theta}(\hat{\theta}_n) = \theta$, pour tout $\theta \in \Theta$

Si on veut $E_{\theta}(\hat{\theta}_n)$ existe.

Un estimateur $\hat{\theta}_n$ de θ est dit sans biais si $E_{\theta}(\hat{\theta}_n) = \theta$

si $E_{\theta}(\hat{\theta}_n) = \theta$.

Exemple 1

$X_n = X_0$ est une échantillon pour tous les $p \in (0, 1)$.

$$E(X_n) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} \cdot n \cdot p = p$$

$$S_n = \frac{1}{n} \sum_{i=1}^n (X_i - p)^2, \quad E(S_n) = \frac{n-1}{n} p^2, \quad (S_n \text{ échantillon biaisé de } p^2)$$

(Par la dérivée de la $\Gamma(x)$).

Définition 6.2

On dit qu'un échantillon $\hat{\theta}$ de θ est asymptotiquement sans biais si et seulement si :

$$\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta \quad \text{ou} \quad \lim_{n \rightarrow \infty} E(\hat{\theta}_n) = \theta$$

Exemple :

$$E(S_n) = \frac{n-1}{n} p^2 \neq p^2, \quad \frac{E(S_n)}{n} = \frac{p^2}{n} \rightarrow 0, \quad \lim_{n \rightarrow \infty} \frac{E(S_n)}{n} = 0$$

$$\text{ou} \quad \lim_{n \rightarrow \infty} E(S_n) = p^2$$

Donc un échantillon biaisé peut être asymptotiquement sans biais.

Exemple 2

$$X_n \text{ est une suite pour } S_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

S_n^2 est un échantillon sans biais de S^2 , appelé échantillon de la variance corrigé.

$$E(S_n^2) = E\left(\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2\right) = \frac{1}{n-1} E\left(\sum_{i=1}^n (X_i - \bar{X})^2\right) = \frac{1}{n-1} \cdot (n-1) S^2 = S^2$$

6. Risque d'un échantillon

On échantillon est une dérivée de grande θ au lieu de θ , le critère qui mesure l'erreur commise de remplacer θ par $\hat{\theta}$, s'appelle fonction de coût (elle mesure l'écart entre $\hat{\theta}$ et θ).

Définition 6.1

On appelle fonction de coût (de perte) toute fonction $L(\cdot, \cdot)$ définie de $\mathbb{C} \times \mathbb{C}$ dans \mathbb{R} , mesurable par la première coordonnée $(\hat{\theta}, \theta) \rightarrow L(\hat{\theta}, \theta)$, $L(\hat{\theta}, \theta)$ est une mesure pour évaluer ce que $\hat{\theta}$ est θ dans $\mathbb{C} \times \mathbb{R}$.

- χ^2 - suit standard : $L(\hat{\theta}, \theta) = |\hat{\theta} - \theta|$
- χ^2 - suit quadratique : $L(\hat{\theta}, \theta) = (\hat{\theta} - \theta)^2$
- χ^2 - suit gaussien : $L(\hat{\theta}, \theta) = \frac{1}{2}(\hat{\theta} - \theta)^2$
- $\theta \in \mathbb{R}^2$ ou \mathbb{R} :
- $L(\hat{\theta}, \theta) = \|\hat{\theta} - \theta\|_2^2$ (la norme euclidienne)
- $L(\hat{\theta}, \theta) = (\hat{\theta} - \theta) \cdot (\hat{\theta} - \theta)^T$ (produit scalaire)

Remarque :

Tous les coûts sont équivariants et dépendent de θ .

Le Risque

Noté $R(\hat{\theta}, \theta)$ le risque associé à la fonction de coût $L(\hat{\theta}, \theta)$ et défini par : $R(\hat{\theta}, \theta) = E[L(\hat{\theta}, \theta)]$

étant qu'en statistique le risque le plus utilisé est le risque quadratique $L(\hat{\theta}, \theta) = (\hat{\theta} - \theta)^2$.

On obtient aussi l'Erreur Quadratique Moyenne définie par :

$$R(\hat{\theta}, \theta) = E[(\hat{\theta} - \theta)^2] \text{ noté RMSE (Mean Squared Error)}$$

$$R(\hat{\theta}, \theta) = \text{Var}(\hat{\theta}) + \mathbb{E}[\hat{\theta} - \theta]^2$$

Si l'estimation est sans biais le risque quadratique est égale à la variance : $R(\hat{\theta}, \theta) = \text{Var}(\hat{\theta})$.

$R(\hat{\theta}, \theta)$ sert aussi à comparer la précision d'un estimateur.

Propriété 6.2 :

Soient $\hat{\theta}_1$ et $\hat{\theta}_2$ deux estimateurs de θ , on dit que

$$\hat{\theta}_1 \text{ est préférable à } \hat{\theta}_2 \text{ si on a : } R(\hat{\theta}_1, \theta) \leq R(\hat{\theta}_2, \theta)$$

pour tout θ de Θ .

Propriété 6.3 :

Un estimateur $\hat{\theta}$ est dit inadmissible s'il existe un autre estimateur qui lui est préférable.