

CONVERGENCE ET ESTIMATION

- 1) Introduction : Le problème central de l'estimation en statistique est le suivant : disposant d'observations sur un échantillon de taille n on souhaite en déduire les propriétés de la population dont il est issu.

On cherchera à estimer, par exemple, la moyenne d'une population à partir de la moyenne d'un échantillon. Le mode de tirage le plus important est l'échantillonnage aléatoire simple correspondant à des tirages équiprobables et indépendants les uns des autres.

L'une des premières qualités d'un estimateur est d'être convergent en probabilité vers le paramètre à estimer. Un échantillon de X est une suite de variables aléatoires $(X_1, X_2, \dots, X_n)$ indépendantes et de même loi que X . Un estimateur d'un paramètre θ inconnu est une fonction $T = f(X_1, X_2, \dots, X_n)$ qui dépend de l'échantillon et donc T doit converger en probabilité vers le paramètre θ . La précision d'un estimateur sera mesuré par sa variance.

- 2) Rappels de la loi Gamma et la loi Normale

On dit qu'une variable aléatoire positive X suit une loi gamma de paramètre

r , notée γ_r si sa densité est donnée par : $f(x) = \frac{1}{\Gamma(r)} \exp(-x)x^{r-1}$

Avec $\Gamma(x) = \int_0^{+\infty} \exp(-t)t^{x-1} dt$ (fonction Gamma) définie pour $x > 0$

Propriétés de la fonction Gamma

(1) $\Gamma(x+1) = x\Gamma(x)$ (intégration par partie)

(2) $\Gamma(1) = 1$

(3) $\Gamma(n+1) = n!$

(4) $\Gamma(k + \frac{1}{2}) = \frac{1.3.5 \dots (2k-1)}{2^k} \Gamma(\frac{1}{2})$

(5) $\Gamma(\frac{1}{2}) = \sqrt{\pi}$

Espérance de la loi γ_r : Soit X une variable aléatoire suivant la loi gamma de paramètre r

On a $E(X) = \frac{1}{\Gamma(r)} \int_0^{+\infty} t \exp(-t) t^{r-1} dt = \frac{1}{\Gamma(r)} \int_0^{+\infty} t^r \exp(-t) dt = \frac{\Gamma(r+1)}{\Gamma(r)} = r$

Variance de la loi γ_r : $V(X) = E(X^2) - E^2(X)$

$$E(X^2) = \frac{1}{\Gamma(r)} \int_0^{+\infty} t^2 \exp(-t) t^{r-1} dt = \frac{1}{\Gamma(r)} \int_0^{+\infty} t^{r+1} \exp(-t) dt = \frac{\Gamma(r+2)}{\Gamma(r)} = r(r+1)$$

Donc $V(X) = r(r+1) - r^2 = r$

Loi Normale de paramètres (m, σ)

On dit qu'une variable aléatoire X suit la loi normale notée $N(m, \sigma)$, si sa densité est $f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp(-\frac{1}{2}(\frac{x-m}{\sigma})^2)$ où $m = E(X)$ et $\sigma = \sqrt{V(X)}$ (écart type)

Avec le changement de variable $U = \frac{X-m}{\sigma}$ (variable normale centrée réduite), la densité de U est $f(u) = \frac{1}{\sqrt{2\pi}} \exp(-\frac{1}{2}u^2)$

Montrons que $V(U) = 1$

On a $V(U) = E(U^2) = \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi}} u^2 \exp(-\frac{1}{2}u^2) du = \frac{2}{\sqrt{2\pi}} \int_0^{+\infty} u^2 \exp(-\frac{1}{2}u^2) du$

Posons $t = \frac{u^2}{2}$, $dt = u du$

$$V(U) = \frac{2}{\sqrt{2\pi}} \int_0^{+\infty} 2t \exp(-t) \frac{dt}{\sqrt{2t}} = \frac{2}{\sqrt{\pi}} \int_0^{+\infty} t^{\frac{1}{2}} \exp(-t) dt = \frac{2}{\sqrt{\pi}} \Gamma(\frac{3}{2}) = \frac{2}{\sqrt{\pi}} \frac{1}{2} \Gamma(\frac{1}{2})$$

Donc $V(U) = \frac{1}{\sqrt{\pi}} \sqrt{\pi} = 1$

Moments de la loi normale centrée réduite

Soit U une variable normale centrée réduite, on appelle moment d'ordre k de U : $\mu_k = E(U^k)$

Si $k = 2p+1$ alors $\mu_{2p+1} = 0$ (car fonction impaire)

Si $k = 2p$ alors $\mu_{2p} = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} u^{2p} \exp(-\frac{1}{2}u^2) du = \frac{2}{\sqrt{2\pi}} \int_0^{+\infty} u^{2p} \exp(-\frac{1}{2}u^2) du$

Posons $t = \frac{u^2}{2}$, $dt = u du$

$$\mu_{2p} = \frac{2}{\sqrt{2\pi}} \int_0^{+\infty} (2t)^p \exp(-t) \frac{dt}{\sqrt{2t}} = \frac{2^p}{\sqrt{\pi}} \int_0^{+\infty} t^{p-\frac{1}{2}} \exp(-t) dt = \frac{2^p}{\sqrt{\pi}} \Gamma(p + \frac{1}{2})$$

$$\text{Or } \Gamma(p + \frac{1}{2}) = \frac{1.3.5.....(2p-1)}{2^p} \Gamma(\frac{1}{2}) \quad \text{et} \quad \Gamma(\frac{1}{2}) = \sqrt{\pi}$$

$$\text{Donc } \mu_{2p} = 1.3.5.....(2p-1) = \frac{(2p)!}{2^p p!}$$

3) Fonctions caractéristiques

Définition : la fonction caractéristique d'une variable aléatoire réelle X est la transformée de Fourier de sa loi de probabilité. elle est notée $\varphi_X(t)$ et

On a $\varphi_X(t) = E(\exp(itX))$ (i complexe)

Si X est une variable à densité (X est une v.a continue de densité f) alors :

$$\varphi_X(t) = \int_{\mathbb{R}} \exp(itx) f(x) dx$$

Si X est une variable discrète alors sa fonction caractéristique est :

$$\varphi_X(t) = \sum_k \exp(itk) P(X = k)$$

Propriétés

$$1) \varphi_{\lambda X}(t) = \varphi_X(\lambda t) \quad \forall \lambda \text{ un scalaire}$$

$$2) \varphi_{X+a}(t) = \exp(ita) \varphi_X(t) \quad \forall a \text{ un scalaire}$$

3) Si X est une variable aléatoire d'espérance m et d'écart type σ

$$\text{Et } U = \frac{X - m}{\sigma}$$

$$\varphi_{\frac{X-m}{\sigma}}(t) = \varphi_U(t) = \exp(-\frac{itm}{\sigma}) \varphi_X(\frac{t}{\sigma})$$

Remarque : la fonction caractéristique se prête bien aux additions de

Variables aléatoires indépendantes :

Si X et Y sont deux variables aléatoires indépendantes alors

$$\varphi_{X+Y}(t) = \varphi_X(t) \cdot \varphi_Y(t)$$

$$\text{En effet } \varphi_{X+Y}(t) = E(\exp(it(X+Y))) = E(\exp(itX) \exp(itY))$$

$$\text{Or X et Y sont indépendantes } E(\exp(itX) \exp(itY)) = E(\exp(itX)) E(\exp(itY))$$

Donc $\varphi_{X+Y}(t) = \varphi_X(t)\varphi_Y(t)$

Proposition : Soit X une variable aléatoire de fonction de répartition $\varphi_X(t)$

On a $\varphi_X(0) = 1$ et $\frac{d^k \varphi_X}{dt^k}(0) = \varphi_X^{(k)}(0) = t^k E(X^k)$

Démo : supposons que X est une variable continue de densité f

On a $\varphi_X(t) = \int_{\mathbb{R}} \exp(itx) f(x) dx \Rightarrow \varphi_X(0) = \int_{\mathbb{R}} f(x) dx = 1$ (car f est une densité)

En dérivant $\varphi_X(t)$ par rapport à t : $\varphi'_X(t) = i \int_{\mathbb{R}} x \exp(itx) f(x) dx$

Si $t=0$ $\varphi'_X(0) = i \int_{\mathbb{R}} x f(x) dx = iE(X)$

Si on dérive 2 fois , $\varphi_X^{(2)}(t) = \int_{\mathbb{R}} (ix)^2 \exp(itx) f(x) dx$

Pour $t=0$, on a $\varphi_X^{(2)}(0) = (i)^2 \int_{\mathbb{R}} x^2 f(x) dx = - \int_{\mathbb{R}} x^2 f(x) dx = -E(X^2)$

En dérivant k fois par rapport à t : $\varphi_X^{(k)}(t) = \int_{\mathbb{R}} (ix)^k \exp(itx) f(x) dx$

Donc $\varphi_X^{(k)}(0) = (i^k) \int_{\mathbb{R}} x^k f(x) dx = i^k E(X^k) \quad \forall k \in \mathbb{N}$

Formule de Mac-Laurin

Si $\varphi_X(t)$ est indéfiniment dérivable on a :

$$\varphi_X(t) = \sum_{k=0}^{+\infty} \frac{t^k}{k!} \varphi_X^{(k)}(0) = \sum_{k=0}^{+\infty} \frac{t^k}{k!} i^k E(X^k)$$

Exemple1 : Soit X une variable aléatoire continue de densité :

$$f(x) = \exp(-x) \text{ si } x > 0 \text{ et } f(x) = 0 \text{ sinon}$$

Déterminer la fonction caractéristique de X

$$\text{On a } \varphi_X(t) = \int_{\mathbb{R}} \exp(itx) f(x) dx = \int_0^{+\infty} \exp(itx) \exp(-x) dx = \int_0^{+\infty} \exp(-(1-it)x) dx$$

$$\varphi_X(t) = \int_0^{+\infty} \exp(-(1-it)x) dx = \left[\frac{-\exp(-(1-it)x)}{(1-it)} \right]_0^{+\infty} = \frac{1}{1-it}$$

Car $\exp(-(1-it)x) = \exp(-x)\exp(itx) \rightarrow 0$ lorsque $x \rightarrow +\infty$

Puisque $\exp(itx)$ est bornée de module 1 et $\exp(-x) \rightarrow 0$ quand $x \rightarrow +\infty$

Exemple2 : Déterminer la fonction caractéristique de la loi de Bernoulli de paramètre p

Soit X une variable de Bernoulli :

$X = 1$ avec la probabilité p et $X = 0$ avec la probabilité 1-p

X étant discrète, donc sa fonction caractéristique est :

$$\varphi_X(t) = \sum_k \exp(itk)P(X = k) = \sum_{k=0}^1 \exp(itk)P(X = k) = P(X = 0) + \exp(it)P(X = 1)$$

$$\varphi_X(t) = 1 - p + p \exp(it) = q + p \exp(it) \text{ avec } q = 1 - p$$

4) Convergences des suites de variables aléatoires

Une suite (X_n) de variables aléatoires étant une suite de fonctions il existe diverses façons de définir la convergence de (X_n) dont certaines jouent un grand rôle en statistiques.

a) Convergence en probabilité

Définition

La suite (X_n) converge en probabilité vers une variable aléatoire X

Si $\forall \varepsilon > 0, \eta > 0$ (arbitrairement petits) il existe un entier n_0 tel que

$$\forall n > n_0 \Rightarrow P(|X_n - X| > \varepsilon) < \eta$$

$$\text{C'est-à-dire } P(|X_n - X| > \varepsilon) \xrightarrow{n \rightarrow +\infty} 0$$

$$\text{On notera } (X_n) \xrightarrow{P} X$$

Inégalité de Bienaymé-Tchebychev

$$P(|X - E(X)| > \varepsilon) < \frac{V(X)}{\varepsilon^2} \quad \forall \varepsilon > 0$$

Remarque : Lorsque $E(X_n) \xrightarrow{n \rightarrow +\infty} a$, il suffit de montrer que

$$V(X_n) \xrightarrow{n \rightarrow +\infty} 0 \text{ pour établir la convergence en probabilité de}$$

La suite (X_n) vers a.

En effet d'après Tchebychev : $P(|X_n - E(X_n)| > \varepsilon) < \frac{V(X_n)}{\varepsilon^2} \rightarrow 0$

Donc en passant à la limite : $\lim_{n \rightarrow +\infty} P(|X_n - a| > \varepsilon) = 0 \quad \forall \varepsilon > 0$

b) Convergence en moyenne quadratique

On suppose que $E(|X_n - X|^2)$ existe

Définition

On dit qu'une suite de variables aléatoires (X_n) converge en moyenne quadratique vers une variable X si $E(|X_n - X|^2) \xrightarrow{n \rightarrow +\infty} 0$

on notera $(X_n) \xrightarrow{m.q} X$

c) Convergence en loi

Définition

La suite (X_n) converge en loi vers la variable X de fonction de répartition F si en tout point de continuité de F la suite (F_n) des fonctions de répartition des (X_n) converge vers F

C'est-à-dire $\lim_{n \rightarrow +\infty} F_n(x) = F(x)$ pour tout x point de continuité de F

On notera $(X_n) \xrightarrow{L} X$

Remarque : Pour les variables discrètes, la convergence en loi est équivalente à $\lim_{n \rightarrow +\infty} P(X_n = k) = P(X = k)$

Théorème : Si la suite des fonctions caractéristiques $\varphi_{X_n}(t)$ converge vers $\varphi_X(t)$ alors $(X_n) \xrightarrow{L} X$

5) Applications

Convergence en loi de la binomiale vers la loi Normale

Théorème (Moivre-laplace)

Soit (X_n) une suite de variables binomiales $B(n, p)$

Alors $\frac{X_n - np}{\sqrt{npq}} \xrightarrow{L} N(0,1)$ lorsque $n \rightarrow +\infty$

Démonstration : la fonction caractéristique de la loi $B(n, p)$ est :

$\varphi_{X_n}(t) = (p \exp(it) + 1 - p)^n$ donc celle de $Y_n = \frac{X_n - np}{\sqrt{npq}}$ est :

$$\varphi_{Y_n}(t) = (p \exp(\frac{it}{\sqrt{npq}}) + 1 - p)^n \exp(\frac{-itnp}{\sqrt{npq}})$$

$$\ln(\varphi_{Y_n}(t)) = n \ln(p(\exp(\frac{it}{\sqrt{npq}}) - 1) + 1) - \frac{itnp}{\sqrt{npq}}$$

On rappelle le développement limité de l'exponentielle à l'ordre 2

$$\exp(x) \approx 1 + x + \frac{x^2}{2} \quad (\text{au voisinage de } 0)$$

$$\ln(\varphi_{Y_n}(t)) \approx n \ln(p(\frac{it}{\sqrt{npq}} - \frac{t^2}{2npq}) + 1) - \frac{itnp}{\sqrt{npq}}$$

On rappelle $\ln(1+x) \approx x - \frac{x^2}{2}$ (au voisinage de 0)

$$\text{Donc } \ln(\varphi_{Y_n}(t)) \approx n[\frac{pit}{\sqrt{npq}} - \frac{pt^2}{2npq} + \frac{p^2t^2}{2npq}] - \frac{itnp}{\sqrt{npq}}$$

$$\ln(\varphi_{Y_n}(t)) \approx -\frac{t^2}{2q} + \frac{pt^2}{2q} = \frac{t^2}{2q}(p-1) = -\frac{t^2}{2}$$

En composant par l'exponentielle :

$$\varphi_{Y_n}(t) \approx \exp(-\frac{t^2}{2}) \text{ fonction caractéristique de la loi normale } N(0,1)$$

$$\text{Conclusion : } \frac{X_n - np}{\sqrt{npq}} \xrightarrow{L} N(0,1)$$

Remarque : lorsque n est assez grand on peut donc approximer la loi Binomiale par la loi normale. On donne généralement comme Condition np et $nq > 5$

Il convient cependant d'effectuer la correction de continuité :

On obtient donc une valeur approchée de $P(X=x)$ par la surface sous

La courbe de densité de la loi normale $N(np, \sqrt{npq})$ comprise entre

Les droites d'abscisse $x - \frac{1}{2}$ et $x + \frac{1}{2}$

$$P(X = x) \approx P(x - \frac{1}{2} < X < x + \frac{1}{2}) = P(\frac{x - \frac{1}{2} - np}{\sqrt{npq}} < \frac{X - np}{\sqrt{npq}} < \frac{x + \frac{1}{2} - np}{\sqrt{npq}})$$

$$\text{Et } P(X \leq x) \approx P\left(\frac{X - np}{\sqrt{npq}} < \frac{x + \frac{1}{2} - np}{\sqrt{npq}}\right)$$

Exemple : Soit X une variable binomiale B(n=40 ;p=0,3)

La valeur exacte pour $P(X = 11)$ est 0,1319

La formule d'approximation :

$$P(X = 11) \approx P\left(\frac{11 - \frac{1}{2} - 12}{\sqrt{8,4}} < \frac{X - 12}{\sqrt{8,4}} < \frac{11 + \frac{1}{2} - 12}{\sqrt{8,4}}\right) = P(-0,52 < U < -0,17) = 0,131$$

Avec $np = 12$ et $npq = 8,4$

Donc l'erreur est de moins de 1%

Convergence en loi de la loi de Poisson vers la loi normale

Théorème : Soit (X_λ) une suite de variables de Poisson de paramètre λ

Alors si $\lambda \rightarrow +\infty$, $\frac{X_\lambda - \lambda}{\sqrt{\lambda}} \xrightarrow{L} N(0,1)$

Démo : on rappelle la fonction caractéristique de la loi de Poisson :

$$\varphi_{X_\lambda}(t) = \exp(\lambda \exp(it) - \lambda)$$

On rappelle aussi la formule $\varphi_{\frac{X-m}{\sigma}}(t) = \exp(-\frac{itm}{\sigma})\varphi_X(\frac{t}{\sigma})$

Donc la fonction caractéristique de la variable $\frac{X_\lambda - \lambda}{\sqrt{\lambda}}$ est :

$$\varphi_{\frac{X_\lambda - \lambda}{\sqrt{\lambda}}}(t) = \exp(-\frac{it\lambda}{\sqrt{\lambda}})\varphi_X(\frac{t}{\sqrt{\lambda}}) = \exp(-\frac{it\lambda}{\sqrt{\lambda}})\exp(\lambda \exp(i\frac{t}{\sqrt{\lambda}}) - \lambda)$$

En utilisant le développement limité à l'ordre 2 de la fonction expo

$$\exp(\frac{it}{\sqrt{\lambda}}) \approx 1 + \frac{it}{\sqrt{\lambda}} - \frac{t^2}{2\lambda}$$

$$\text{Donc } \varphi_{\frac{X_\lambda - \lambda}{\sqrt{\lambda}}}(t) = \exp(-\frac{it\lambda}{\sqrt{\lambda}} + \lambda + \frac{\lambda it}{\sqrt{\lambda}} - \frac{t^2}{2} - \lambda) = \exp(-\frac{t^2}{2})$$

On retrouve la fonction caractéristique de la loi normale centrée et réduite.

Conclusion : $\frac{X_\lambda - \lambda}{\sqrt{\lambda}} \xrightarrow{L} N(0,1)$.

Théorème (Central-limite)

Soit (X_n) une suite de variables aléatoires, indépendantes et de même Loi d'espérance m et d'écart-type σ alors :

$$\frac{X_1 + X_2 + \dots + X_n - nm}{\sigma\sqrt{n}} \xrightarrow{L} N(0,1)$$

$$\text{Démonstration : } \frac{X_1 + X_2 + \dots + X_n - nm}{\sigma\sqrt{n}} = \sum_{i=1}^n \frac{X_i - m}{\sigma\sqrt{n}}$$

$$\text{Posons } Y_n = \sum_{i=1}^n \frac{X_i - m}{\sigma\sqrt{n}}$$

$$E\left(\frac{X_i - m}{\sigma\sqrt{n}}\right) = \frac{E(X_i) - m}{\sigma\sqrt{n}} = 0 \quad \text{et} \quad V\left(\frac{X_i - m}{\sigma\sqrt{n}}\right) = \frac{1}{\sigma^2 n} V(X_i) = \frac{\sigma^2}{n\sigma^2} = \frac{1}{n}$$

La fonction caractéristique de $Y_n = \sum_{i=1}^n \frac{X_i - m}{\sigma\sqrt{n}}$ est :

$$\varphi_{Y_n}(t) = \prod_{i=1}^n \varphi_{\frac{X_i - m}{\sigma\sqrt{n}}}(t) = \left(\varphi_{\frac{X_i - m}{\sigma\sqrt{n}}}(t)\right)^n = \left(1 - \frac{t^2}{2n} + o\left(\frac{1}{n^2}\right)\right)^n$$

On rappelle que $\left(1 + \frac{x}{n}\right)^n \rightarrow \exp(x)$ lorsque $n \rightarrow +\infty$

$$\text{Car } \left(1 + \frac{x}{n}\right)^n = e^{n \ln\left(1 + \frac{x}{n}\right)} \approx e^{n \frac{x}{n}} = e^x$$

$$\text{Donc } \varphi_{Y_n}(t) = \left(1 - \frac{t^2}{2n} + o\left(\frac{1}{n^2}\right)\right)^n \rightarrow e^{-\frac{t^2}{2}} \text{ lorsque } n \rightarrow +\infty$$

Ce qui montre la convergence en loi vers la loi normale

6) Estimateurs

Définition : Soit $(X_1, X_2, \dots, X_n)$ un échantillon de X c'est-à-dire une suite de variables aléatoires indépendantes et de même loi que X

La statistique $\bar{X}$ ou moyenne empirique de l'échantillon est

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

$$E(\bar{X}) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{nm}{n} = m \quad \text{où } m = E(X)$$

$$V(\bar{X}) = \frac{1}{n^2} \sum_{i=1}^n V(X_i) = \frac{n\sigma^2}{n^2} = \frac{\sigma^2}{n} \rightarrow 0 \text{ lorsque } n \rightarrow +\infty$$

$$\text{Donc d'après Tchebychev } \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{P} m = E(X) \text{ quand } n \rightarrow +\infty$$

C'est la loi des grands nombres.

$\bar{X}$ est un exemple d'estimateur de la moyenne $m = E(X)$

Définition On appelle variance empirique, la statistique :

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

Proposition : $S^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - (\bar{X})^2$

Démo : $S^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n} \sum_{i=1}^n (X_i^2 - 2X_i \bar{X} + \bar{X}^2)$

$$S^2 = \frac{1}{n} \sum_{i=1}^n (X_i^2 - 2X_i \bar{X} + \bar{X}^2) = \frac{1}{n} \sum_{i=1}^n X_i^2 - 2\bar{X} \frac{1}{n} \sum_{i=1}^n X_i + \frac{n}{n} \bar{X}^2$$

$$S^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - 2\bar{X}^2 + \bar{X}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - (\bar{X})^2$$

Montrons que $S^2 \xrightarrow{P} \sigma^2$ lorsque $n \rightarrow +\infty$

D'après la loi des grands nombres, on a :

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{P} m = E(X) \text{ quand } n \rightarrow +\infty$$

$$\text{Et } \frac{1}{n} \sum_{i=1}^n X_i^2 \xrightarrow{P} E(X^2) \text{ quand } n \rightarrow +\infty$$

$$\text{Donc } S^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - (\bar{X})^2 \xrightarrow{P} E(X^2) - E^2(X) = \sigma^2 = V(X)$$

S^2 est un estimateur de la variance .

Définition : On considère une population X, distribuée suivant une Loi de probabilité qui dépend d'un paramètre θ inconnu.

On prélève un échantillon $(X_1, X_2, \dots, X_n)$ de X, on appelle estimateur de θ , toute variable aléatoire T_n fonction de l'échantillon :

$$T_n = f(X_1, X_2, \dots, X_n)$$

On appelle biais de l'estimateur la quantité $b(T_n) = E(T_n) - \theta$

On dit que l'estimateur est sans biais si $b(T_n) = 0 \Leftrightarrow E(T_n) = \theta$

Comme exemple $\bar{X}$ est un estimateur sans biais de $m = E(X)$

Puisque $E(\bar{X}) = m$

Définition : On dit qu'une suite (T_n) d'estimateurs de θ est

asymptotiquement sans biais si $\lim_{n \rightarrow +\infty} E(T_n) = \theta$

On appelle risque quadratique de T_n ou erreur quadratique :

$$R(T_n) = E((T_n - \theta)^2)$$

Proposition : le risque quadratique est $R(T_n) = V(T_n) + (E(T_n) - \theta)^2$

Démonstration :

$$(T_n - \theta)^2 = (T_n - E(T_n) + E(T_n) - \theta)^2$$

$$E((T_n - \theta)^2) = E((T_n - E(T_n))^2) + 2E((T_n - E(T_n))(E(T_n) - \theta)) + E((E(T_n) - \theta)^2)$$

$$E((T_n - \theta)^2) = V(T_n) + 2(E(T_n) - \theta)(E(T_n) - E(T_n)) + (E(T_n) - \theta)^2$$

$$\text{Donc } R(T_n) = V(T_n) + (E(T_n) - \theta)^2$$

Remarque : Si l'estimateur est sans biais $b(T_n) = E(T_n) - \theta = 0$

$$\text{Alors } R(T_n) = V(T_n)$$

Donc si on a deux estimateurs sans biais du paramètre θ

Le plus précis est celui de variance minimale.

Définition : On dit que l'estimateur T_n est convergent si cet

Estimateur converge en probabilité vers le paramètre θ .

on écrira $T_n \xrightarrow{P} \theta$ lorsque $n \rightarrow +\infty$

Définition : On appelle vraisemblance de θ , la densité de

L'échantillon $(X_1, X_2, \dots, X_n)$:

$$L(x_1, x_2, \dots, x_n, \theta) = \prod_{i=1}^n P(X_i = x_i) \quad (\text{dans le cas discret})$$

$$L(x_1, x_2, \dots, x_n, \theta) = \prod_{i=1}^n f(x_i) \quad (\text{dans le cas continu})$$

Exemple : On considère un échantillon $(X_1, X_2, \dots, X_n)$ d'une variable de Poisson de paramètre θ (inconnu)

la vraisemblance de cet échantillon est : $L(x_1, x_2, \dots, x_n, \theta) = \prod_{i=1}^n P(X_i = x_i)$

$$L(x_1, x_2, \dots, x_n, \theta) = \prod_{i=1}^n \exp(-\theta) \frac{\theta^{x_i}}{x_i!} = \frac{\exp(-n\theta) \theta^{\sum_{i=1}^n x_i}}{\prod_{i=1}^n x_i!}$$

Définition : On appelle quantité d'information de Fisher $I_n(\theta)$ apportée par

Un échantillon sur le paramètre θ la quantité positive : $I_n(\theta) = E((\frac{\partial \ln L}{\partial \theta})^2)$

Proposition :

$$I_n(\theta) = -E(\frac{\partial^2 \ln L}{\partial \theta^2})$$

Démo : L étant une densité : $\int_{\mathbb{R}^n} L(x, \theta) dx = 1$

En dérivant par rapport à θ : $\int_{\mathbb{R}^n} \frac{\partial L(x, \theta)}{\partial \theta} dx = 0 \quad (1)$

en remarquant que $\frac{\partial \ln L(x, \theta)}{\partial \theta} = \frac{\frac{\partial L}{\partial \theta}(x, \theta)}{L(x, \theta)}$

(1) donne $\int_{\mathbb{R}^n} \frac{\partial \ln L(x, \theta)}{\partial \theta} L(x, \theta) dx = 0$

ce qui prouve que la variable aléatoire $\frac{\partial \ln L(x, \theta)}{\partial \theta}$ est centrée et que

$$I_n(\theta) = V(\frac{\partial \ln L}{\partial \theta})$$

Dérivons une deuxième fois par rapport à θ :

$$\int_{\mathbb{R}^n} \frac{\partial^2 \ln L(x, \theta)}{\partial \theta^2} L(x, \theta) dx + \int_{\mathbb{R}^n} \frac{\partial \ln L(x, \theta)}{\partial \theta} \frac{\partial L(x, \theta)}{\partial \theta} dx = 0$$

$$\int_{\mathbb{R}^n} \frac{\partial^2 \ln L(x, \theta)}{\partial \theta^2} L(x, \theta) dx + \int_{\mathbb{R}^n} \left(\frac{\partial \ln L(x, \theta)}{\partial \theta} \right)^2 L(x, \theta) dx = 0$$

Donc

$$I_n(\theta) = E\left(\left(\frac{\partial \ln L}{\partial \theta}\right)^2\right) = \int_{\mathbb{R}^n} \left(\frac{\partial \ln L(x, \theta)}{\partial \theta}\right)^2 L(x, \theta) dx = - \int_{\mathbb{R}^n} \frac{\partial^2 \ln L(x, \theta)}{\partial \theta^2} L(x, \theta) dx = -E\left(\frac{\partial^2 \ln L(x, \theta)}{\partial \theta^2}\right)$$

Inégalité de FRECHET-DARMOIS-CRAMER-RAO(FDCR)

On a pour tout estimateur T sans biais de θ : $V(T) \geq \frac{1}{I_n(\theta)}$

L'estimateur T sera qualifié d'efficace si la borne inférieure est atteinte

C'est-à-dire $V(T) = \frac{1}{I_n(\theta)}$

Méthode du maximum de vraisemblance

Cette méthode consiste, étant donnée un échantillon de valeurs $x_1, x_2, \dots, x_n$ à prendre comme estimation de θ la valeur de θ qui rend maximale la vraisemblance $L(x_1, x_2, \dots, x_n, \theta)$.

En fait, on prend comme estimation de θ la solution de l'équation de

la vraisemblance : $\frac{\partial \ln L}{\partial \theta} = 0$