

Chapitre 23 : Estimation

1. Notion d'estimateur

1.1 Principe général

Soit X une variable aléatoire. On suppose que cette loi dépend d'un **paramètre θ** (loi de Bernoulli de paramètre p , loi de Poisson de paramètre λ ...), qui est **inconnu**.

On suppose que θ appartient à un ensemble Θ .

Soit $(X_n)_{n \geq 1}$ une suite de **variables indépendantes** et qui suivent toutes la même loi que X .

(On répète par exemple l'expérience de manière indépendante)

Si $n \geq 1$, (X_1, \dots, X_n) est appelé un **n-échantillon**

On va essayer d'**estimer la valeur de θ** , à l'aide des valeurs prises par l'échantillon (X_1, X_2, \dots, X_n) .

Définition :

Avec les hypothèses précédentes, on appelle **estimateur de θ** , toute variable aléatoire $T_n = f(X_1, \dots, X_n)$, où f est une application de \mathbb{R}^n dans \mathbb{R} , telle que T_n est une variable aléatoire.

Exemples : Avec les hypothèses précédentes

$T_n = \frac{X_1 + \dots + X_n}{n}$, $T_n = \frac{X_{n-1} + X_n}{2}$, $T_n = \text{Max}(X_1, \dots, X_n)$, $T_n = (X_1 X_2 \dots X_n)^{1/n}$ (si $X_i \geq 0$) sont des

estimateurs de θ .

Remarque :

Pour obtenir un bon estimateur de θ , les valeurs prises par T_n doivent être proches de θ .

Pour cela on veillera à ce que :

- _ l'espérance de T_n soit égale à θ , ou au moins tende vers θ quand n tend vers $+\infty$
- _ la variance de T_n soit la plus petite possible, et tende vers 0 quand n tend vers $+\infty$.

1.2 Exemple d'étude d'un estimateur : la moyenne empirique

Soit $\lambda > 0$. Soit $(X_n)_{n \geq 1}$ une suite de variables aléatoires indépendantes qui suivent toutes la loi de Poisson

de paramètre λ . Pour $n \geq 1$, on pose $T_n = \frac{X_1 + \dots + X_n}{n}$.

1) Montrer que T_n est un estimateur de λ .

2) Déterminer $E(T_n)$ et $V(T_n)$. Cet estimateur semble-t-il intéressant ?

Rappel : Loi faible des grands nombres

Si $(X_i)_{i \geq 1}$ est une suite de variables indépendantes de même loi, qui admettent une espérance m et une variance, et si $T_n = \frac{X_1 + \dots + X_n}{n}$, alors $\forall \varepsilon > 0, \lim_{n \rightarrow +\infty} P(|T_n - m| > \varepsilon) = 0$.

En d'autres termes, T_n "tend vers" m . (On dit que (T_n) converge en probabilité vers m)

En Python :

Rappel : Si x est un vecteur qui contient les résultats de n simulations de la variable aléatoire, **np.mean(x)** calcule la moyenne de ces n valeurs.

Si n est grand, la valeur trouvée sera donc très proche de m .

2. Intervalles de confiance

Définition :

Soit $\theta \in \mathbb{R}$ et $\alpha \in]0;1[$. Soit $(U_n$ et $V_n)$ deux estimateurs issus d'un échantillon (X_1, \dots, X_n) .

On dit que $[U_n, V_n]$ est un **intervalle de confiance de θ au niveau de confiance $1 - \alpha$** , (ou au niveau de risque α) si : **$P(U_n \leq \theta \leq V_n) \geq 1 - \alpha$**

Remarques :

_ si T_n est un estimateur de θ et $\varepsilon > 0$,

$$\theta \in [T_n - \varepsilon; T_n + \varepsilon] \Leftrightarrow T_n - \varepsilon \leq \theta \leq T_n + \varepsilon$$

$$\Leftrightarrow -\varepsilon \leq \theta - T_n \leq \varepsilon$$

$$\Leftrightarrow |\theta - T_n| \leq \varepsilon$$

$$\Leftrightarrow |T_n - \theta| \leq \varepsilon$$

$$\Leftrightarrow -\varepsilon \leq T_n - \theta \leq \varepsilon$$

$$\Leftrightarrow \theta - \varepsilon \leq T_n \leq \theta + \varepsilon$$

Pour déterminer un intervalle de confiance, on peut utiliser par exemple **l'inégalité de Bienaymé-Tchebychev**. (Exemple page suivante)

Exemple :

On lance indéfiniment une pièce truquée dont la probabilité de faire pile est $p \in]0;1[$.

Pour tout $i \geq 1$, on considère la VAR X_i définie par : $X_i = 1$ si on obtient pile au i -ème lancer, $X_i = 0$ sinon.

Posons $Z_n = X_1 + \dots + X_n$ et $Y_n = \frac{Z_n}{n} = \frac{X_1 + \dots + X_n}{n}$

On notera $\sigma^2 = p(1-p)$.

1) Montrer que : $\forall x \in [0;1], x(1-x) \leq 1/4$

2) Déterminer l'espérance et la variance de Y_n .

3) Montrer que $\forall \varepsilon > 0, P(|Y_n - E(Y_n)| \leq \varepsilon) \geq 1 - \frac{1}{4n\varepsilon^2}$.

4) Déterminer un rang n pour lequel $[Y_n - 0,01; Y_n + 0,01]$ est un intervalle de confiance de p au niveau de confiance 0,95.

Définition :

Soit $\theta \in \mathbb{R}$ et $\alpha \in]0;1[$. Soit $(U_n$ et $V_n)$ deux estimateurs issus d'un échantillon (X_1, \dots, X_n) .

On dit que $[U_n, V_n]$ est un **intervalle de confiance asymptotique de θ au niveau de confiance $1 - \alpha$** , (ou au niveau de risque α) si $\lim_{n \rightarrow +\infty} P(U_n \leq \theta \leq V_n) \geq 1 - \alpha$

Remarques :

_ Pour trouver un intervalle de confiance asymptotique, on utilise en particulier **le théorème de la limite centrée**

_ Pour plus de simplicité, dans certains exercices, on approche directement la loi par la loi normale (pour n grand)

Ex : Suite de l'exemple précédent

1) Montrer que $\forall x > 0, \lim_{n \rightarrow +\infty} P\left(Y_n - \frac{x\sigma}{\sqrt{n}} \leq p \leq Y_n + \frac{x\sigma}{\sqrt{n}}\right) = 2\Phi(x) - 1$.

2) En déduire un intervalle de confiance asymptotique de p à 95%.

3) Application : On lance 10000 fois la pièce, et on obtient 2345 fois Pile.

Déterminer un intervalle de confiance de p à 95%.

3. Exemple : maximum de vraisemblance

Aucune théorie n'est à connaître dans ce paragraphe.

Soit $\theta \in \Theta$ et (X_1, \dots, X_n) un n-échantillon, tel que (X_1, \dots, X_n) sont indépendantes entre elles, et suivent la même loi qu'une variable aléatoire X .

Principe :

On observe dans une expérience que X_1 prend la valeur x_1 , X_2 prend la valeur x_2 , ... X_n prend la valeur x_n .

On cherche la valeur de θ qui rend maximale la probabilité de cet événement :

Pour $\theta \in \Theta$, on pose $L(\theta) = P((X_1 = x_1) \cap \dots \cap (X_n = x_n))$
 $= P(X_1 = x_1) \times \dots \times P(X_n = x_n)$ par indépendance.

On exprime $L(\theta)$ en fonction de θ , puis on étudie les variations de cette fonction pour trouver son maximum (on s'aidera souvent de son logarithme).

Ex : On suppose que X_1, \dots, X_n sont des VAR indépendantes qui suivent toutes la loi de poisson $\mathcal{P}(\theta)$. ($\theta > 0$).

Pour $(x_1, \dots, x_n) \in \mathbb{N}^n$, on pose $L(\theta) = P((X_1 = x_1) \cap \dots \cap (X_n = x_n))$ et $f(\theta) = \ln(L(\theta))$.

On pose : $s_n = x_1 + \dots + x_n$ et $t_n = (x_1)! \times \dots \times (x_n)!$

- 1) Exprimer $f(\theta)$ en fonction de θ , n , s_n et t_n .
- 2) Etudier les variations de f .
- 3) Montrer que L admet un maximum en une valeur θ_0 que l'on précisera.