

## I. Introduction

Les statisticiens connaissent en général, le type de loi qui décrit tel ou tel phénomène (de par l'observation), mais souvent, il ne connaissent pas tous les paramètres de cette loi. Ils cherchent alors à estimer ces paramètres non connus : c'est tout l'objectif de la **statistique inférentielle** (inférer = déduire).

On considère une variable aléatoire  $X$  dont le type de loi est connu et dépend d'un paramètre  $\theta$ , qui peut être un réel, comme par exemple le paramètre  $\lambda$  d'une loi de Poisson, ou un élément de  $\mathbb{R}^2$  comme le couple  $(m, \sigma^2)$  d'une loi normale. On suppose alors que  $\theta$  appartient à une partie de  $\mathbb{R}$  ou de  $\mathbb{R}^2$ , et on note  $\Theta$  cette partie.

**L'objectif est alors de donner une estimation de la vraie valeur de  $\theta$ .**

On cherchera parfois à estimer un réel  $g(\theta)$  où  $g$  est une fonction simple. Dans ce cas  $g(\theta)$  sera en général une valeur caractéristique de la loi inconnue, comme son espérance, sa variance, son étendue...

L'estimation de  $\theta$  se fera à partir d'un échantillon de données  $x_1, \dots, x_n$  obtenu en observant  $n$  fois le phénomène.

On suppose que cet échantillon est la réalisation de  $n$  variables aléatoires  $X_1, X_2, \dots, X_n$ , définies sur un même espace probabilisé  $(\Omega, \mathcal{A})$  muni d'une famille de probabilités  $(P_\theta)_{\theta \in \Theta}$ . Les variables aléatoires  $X_1, \dots, X_n$  sont supposées mutuellement indépendantes (pour la probabilité  $P_\theta$ ) et de même loi que  $X$ .

L'idée est de prendre  $n$  grand pour bien rendre compte du phénomène.

**Exemple 1 :** On étudie les truites d'un lac de montagne et on s'intéresse à la probabilité  $p$  qu'une truite soit atteinte d'une maladie donnée. On considère  $X \hookrightarrow \mathcal{B}(p)$  et on cherche à estimer  $p$  ( $X$  vaut 1 si la truite est malade et 0 sinon).

Pour cela, on prélève  $n$  truites et on note  $X_1, \dots, X_n$  les variables de Bernoulli associées à la truite numéro 1, ..., , numéro  $n$ .

**Exemple 2 :** on sait qu'il existe deux réels  $a$  et  $b$  tels que  $a < b$  et  $X \hookrightarrow \mathcal{U}([a, b])$  mais on ne connaît pas  $a$  et  $b$ . Pour se simplifier la vie on cherchera à estimer un seul paramètre inconnu, ici la moyenne  $m = \frac{a+b}{2}$  ou l'étendue  $b-a$ .

**Exemple 3 :** on souhaite modéliser le nombre  $N$  de voitures se présentant à un péage en une heure. Ce type de variable aléatoire suit une loi de Poisson; on cherchera à estimer le paramètre de cette loi.

Il y a deux types d'estimation : l'**estimation ponctuelle** et l'**estimation par intervalle de confiance**.

Dans tout ce cours,  $n$  désignera un entier naturel supérieur ou égal à 2.

## II. Echantillonage

### Définition II.1 Échantillon de taille $n$

Soit  $X$  une variable aléatoire réelle.

On appelle  **$n$ -échantillon** (ou échantillon de taille  $n$ ) issue de la variable aléatoire  $X$ , tout vecteur aléatoire  $(X_1, \dots, X_n)$  vérifiant les propriétés suivantes :

- les variables aléatoires  $X_1, X_2, \dots, X_n$  ont même loi que la variable aléatoire  $X$ .
- les variables aléatoires  $(X_i)_{1 \leq i \leq n}$  sont indépendantes

On dit alors que  $(X_1, \dots, X_n)$  est un  **$n$ -échantillon i.i.d.** (indépendant, identiquement distribué)

On appelle **réalisation de l'échantillon**  $(X_1, \dots, X_n)$  toute  $n$ -liste de réels  $(x_1, x_2, \dots, x_n)$  où  $x_i$  est une valeur prise par la variable aléatoire  $X_i$  pour tout  $i \in [[1, n]]$ .

Dans la pratique, pour constituer un échantillon, on effectue  $n$  épreuves, identiques et indépendantes, et  $X_k$  est la VAR égale au résultat de la  $k$ -ième épreuve.

### Remarque

Soit  $X$  une variable aléatoire réelle, dont la loi dépend d'un paramètre  $\theta \in \Theta$ . On peut montrer que pour tout  $\theta \in \Theta$ , il existe des variables aléatoires  $X_1, \dots, X_n$  définies sur un même espace probabilisable  $(\Omega, \mathcal{A})$  et une probabilité  $P_\theta$  (dépendant de  $\theta$ ) telles que les variables  $X_1, \dots, X_n$  sont de même loi que  $X$ , et sont indépendantes pour la probabilité  $P_\theta$ .

On notera ainsi parfois  $P_\theta$  au lieu de  $P$ . Si  $X$  est une variable aléatoire, on notera parfois  $E_\theta(X)$  et  $V_\theta(X)$  l'espérance et la variance de  $X$  pour la probabilité  $P_\theta$ .

## III. Estimateur

### III.1 ) Définition

#### Définition III.1

Soit  $X$  une variable aléatoire qui suit une loi  $\mathcal{L}$ . On suppose que la loi de  $X$  dépend d'un paramètre inconnu  $\theta$ .

Soit  $(X_1, \dots, X_n)$  un  $n$ -échantillon i.i.d. issu de la variable aléatoire  $X$ .

On appelle **estimateur de  $\theta$  ( ou de  $g(\theta)$  )** une variable aléatoire de la forme

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

où  $\varphi$  est une fonction de  $\mathbb{R}^n$  dans  $\mathbb{R}$ . La réalisation  $\varphi(x_1, \dots, x_n)$  de l'estimateur  $T_n$  est l'estimation de  $\theta$  (ou de  $g(\theta)$ ). Cette estimation ne dépend que de l'échantillon  $(x_1, \dots, x_n)$  observé.

### Exemple

Soit  $X$  une variable aléatoire qui suit une loi  $\mathcal{L}$  dépendant d'un paramètre  $\theta$ . On cherche à connaître  $\theta$  (ou son image  $g(\theta)$  par une fonction  $g$ ).

Soit  $(X_1, X_2, \dots, X_n)$  un échantillon de la loi de  $X$ .

- La variable aléatoire  $\frac{1}{n}(X_1 + \dots + X_n)$  est un estimateur de  $\theta$  associé à l'échantillon  $(X_1, \dots, X_n)$ .
- La variable aléatoire  $X_1 \times \dots \times X_n$  est un estimateur de  $\theta$  associé à l'échantillon  $(X_1, \dots, X_n)$ .
- La variable aléatoire  $\min(X_1, \dots, X_n)$  est un estimateur de  $\theta$  associé à l'échantillon  $(X_1, \dots, X_n)$ .

Ces estimateurs peuvent être pertinents ou non !!!

### III.2 ) Moyenne empirique

#### Définition III.2

##### Un estimateur classique : la moyenne empirique

Soit  $X$  une variable aléatoire qui suit une loi  $\mathcal{L}$ . On suppose que la loi de  $X$  dépend d'un paramètre inconnu  $\theta$ .

Soit  $(X_1, X_2, \dots, X_n)$  un échantillon de la loi de  $X$ .

On suppose que  $X$  admet une espérance notée  $m$  et une variance  $\sigma^2 > 0$ .

On appelle **moyenne empirique** de  $X$  sur l'échantillon  $(X_1, \dots, X_n)$ , la variable aléatoire

$$\overline{X_n} = \frac{1}{n} \sum_{i=1}^n X_i$$

#### Proposition III.1

- La moyenne empirique  $\overline{X_n}$  admet un moment d'ordre 2.
- $E(\overline{X_n}) = E(X) = m$
- $V(\overline{X_n}) = \frac{V(X)}{n} = \frac{\sigma^2}{n}$
- La suite  $(\overline{X_n})_{n \in \mathbb{N}^*}$  converge en probabilité vers la variable aléatoire certaine égale à  $m = E(X)$ .
- La variable aléatoire centrée réduite associée à  $\overline{X_n}$  i.e.  $\overline{X_n}^* = \frac{\overline{X_n} - m}{\sqrt{n}}$  converge en loi vers une variable aléatoire de loi normale centrée réduite.

#### Remarque

Il s'agit de reformulations de la loi faible des grands nombres et du Théorème Central Limite.

## IV. Estimation ponctuelle

### IV.1 ) Estimateur sans biais

#### Définition IV.1

Soit  $X$  une variable aléatoire qui suit une loi  $\mathcal{L}$  dépendant d'un paramètre  $\theta$ . On cherche à estimer  $g(\theta)$ .

Soit  $(X_1, X_2, \dots, X_n)$  un échantillon i.i.d. de la loi de  $X$ .

On considère un estimateur de  $g(\theta)$  noté  $T_n = \varphi_n(X_1, X_2, \dots, X_n)$ .

On suppose que  $T_n$  admet une espérance.

On dit que l'estimateur  $T_n$  de  $g(\theta)$  est **sans biais** lorsque  $E(T_n) = g(\theta)$ .

### IV.2 ) Estimateur convergent

#### Définition IV.2

Soit  $X$  une variable aléatoire qui suit une loi  $\mathcal{L}$  dépendant de  $\theta$ , on cherche à connaître  $g(\theta)$ . Pour tout  $n \in \mathbb{N}$ ,  $n \geq 1$ , on considère  $T_n$  un estimateur de  $g(\theta)$ .

On dit que la suite d'estimateurs  $(T_n)_{n \geq 1}$  est **convergente** lorsque la suite de variables  $(T_n)_{n \in \mathbb{N}^*}$  converge en probabilité vers la variable aléatoire certaine égale à  $g(\theta)$ . c'est à dire lorsque :

$$T_n \xrightarrow{P} g(\theta)$$

#### Remarque

Par abus de langage, on dit que l'estimateur  $T_n$  est convergent.

#### Remarque

La moyenne empirique est un estimateur sans biais et convergent de  $m = E(X)$ .

Ce résultat n'est pas explicitement dans le programme : il doit être redémontré à chaque fois via la loi faible des grands nombres.

#### Théorème IV.1

##### Composition par une fonction continue

Soit  $X$  une variable aléatoire qui suit une loi  $\mathcal{L}$  dépendant de  $\theta$

Soit  $T_n$  un estimateur de  $g(\theta)$ . Soit  $f : \mathbb{R} \rightarrow \mathbb{R}$  une fonction **continue** de  $\mathbb{R}$  dans  $\mathbb{R}$ .

Si  $T_n$  est un estimateur convergent alors  $(f(T_n))_{n \geq 1}$  est une suite convergente d'estimateurs de  $f(g(\theta))$ .

#### Remarque

Conséquence immédiate du cours sur la convergence en probabilités.

#### Théorème IV.2

##### Condition suffisante de convergence

Soit  $(T_n)$  une suite d'estimateurs de  $g(\theta)$ .

Si  $\lim_{n \rightarrow +\infty} E(T_n) = g(\theta)$  et  $\lim_{n \rightarrow +\infty} V(T_n) = 0$  alors  $(T_n)$  est convergente

## Preuve

### Preuve de cours à connaître

Soit  $\epsilon > 0$ . Par stricte croissance de la fonction carré sur  $\mathbb{R}_+$ , puis d'après l'inégalité de Markov,

$$P(|T_n - g(\theta)| > \epsilon) = P((T_n - g(\theta))^2 > \epsilon^2) \leq \frac{E((T_n - g(\theta))^2)}{\epsilon^2}$$

De plus,

$$\begin{aligned} E((T_n - g(\theta))^2) &= E(T_n^2 - 2g(\theta)T_n + g(\theta)^2) \\ &= E(T_n^2) - 2g(\theta)E(T_n) + g(\theta)^2 \quad (\text{par linéarité de l'espérance}) \\ &= E(T_n^2) - E(T_n)^2 + E(T_n)^2 - 2g(\theta)E(T_n) + g(\theta)^2 \\ &= V(T_n) + (E(T_n) - g(\theta))^2 \end{aligned}$$

Ainsi

$$P(|T_n - g(\theta)| > \epsilon) \leq \frac{V(T_n)}{\epsilon^2} + \frac{(E(T_n) - g(\theta))^2}{\epsilon^2}$$

et comme  $\lim_{n \rightarrow +\infty} E(T_n) = g(\theta)$  et  $\lim_{n \rightarrow +\infty} V(T_n) = 0$  on a bien  $\lim_{n \rightarrow +\infty} P(|T_n - g(\theta)| > \epsilon) = 0$ , donc  $T_n \xrightarrow{P} g(\theta)$ .

### Remarque

Comme

$$[|T_n - g(\theta)| \leq \epsilon] = [T_n - \epsilon \leq g(\theta) \leq T_n + \epsilon],$$

on en déduit que

$$\lim_{n \rightarrow +\infty} P(g(\theta) \in [T_n - \epsilon, T_n + \epsilon]) = 1$$

On dit que  $[T_n - \epsilon, T_n + \epsilon]$  est un intervalle de confiance asymptotique de  $g(\theta)$ .

## IV.3 ) Comparaison de deux estimateurs

On souhaite comparer deux estimateurs de  $g(\theta)$ , afin de retenir le plus pertinent, c'est-à-dire retenir celui qui en moyenne fournit le résultat le plus proche de  $g(\theta)$ .

Une première idée pourrait être d'éliminer les estimateurs biaisés. Cependant, un estimateur non biaisé ayant une variance importante prendra souvent des valeurs éloignées de  $g(\theta)$ , alors qu'un estimateur faiblement biaisé mais ayant une variance faible pourra fournir des résultats plus proches.

Si  $T_n$  est un estimateur de  $g(\theta)$ , il s'agit d'obtenir  $E(T_n) - g(\theta)$  et  $V(T_n)$  les plus faibles possibles.

Dans la preuve de cours ci-dessus, nous avons montré que pour tout  $\epsilon > 0$ ,

$$P(|T_n - g(\theta)| > \epsilon) \leq \frac{V(T_n) + (E(T_n) - g(\theta))^2}{\epsilon^2}$$

La quantité

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

paraît être un bon outil de comparaison : si cette quantité est faible alors à la fois  $|E(T_n) - g(\theta)|$  et  $V(T_n)$  sont faibles.

Méthode : pour comparer deux estimateurs  $T_n$  et  $U_n$  de  $g(\theta)$ , on calcule leurs espérances et leurs variances.

Puis, si

$$V(T_n) + (E(T_n) - g(\theta))^2 < V(U_n) + (E(U_n) - g(\theta))^2$$

alors l'estimateur  $T_n$  sera plus intéressant que l'estimateur  $U_n$ .

## IV.4 ) Exercices

### Exercice 1

Soit  $X$  une variable aléatoire de loi  $\mathcal{N}(0, \sigma^2)$  de variance  $\sigma^2$  inconnue où  $\sigma > 0$ .

Pour tout  $n \geq 2$ , on considère un  $n$ -échantillon i.i.d.  $(X_1, \dots, X_n)$  de même loi que  $X$ .

On note  $T_n = \frac{1}{n} \sum_{k=1}^n X_k^2$

1. Justifier que la variable  $X$  admet un moment d'ordre 4.

2. Montrer que  $T_n$  est un estimateur sans biais et convergent de  $\sigma^2$ .

### Exercice 2

Une variable aléatoire  $X$  suit la loi uniforme sur le segment  $[0, \theta]$ ,  $\theta$  étant un paramètre strictement positif inconnu.

1. Rappeler une densité  $f_X$ , la fonction de répartition  $F_X$ , l'espérance  $E(X)$  et la variance  $V(X)$  de la variable  $X$ .

Soit  $X_1, X_2, \dots, X_n$  un échantillon de  $n$  observations indépendantes de la variable aléatoire  $X$  ( $n \geq 2$ ). On note  $\bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k$ .

2. Justifier que  $T_n = 2\bar{X}_n$  est un estimateur sans biais et convergent de  $\theta$  que l'on notera  $T_n$ .

3. On considère la variable aléatoire suivante  $Y_n = \max(X_1, \dots, X_n)$ .  
(on note aussi  $Y_n = \text{Sup}(X_1, \dots, X_n)$ ).

(a) Justifier que  $Y_n$  est une variable à densité et déterminer une densité de probabilité  $f_{Y_n}$  de  $Y_n$ .  
Calculer  $E(Y_n)$  et  $V(Y_n)$ .

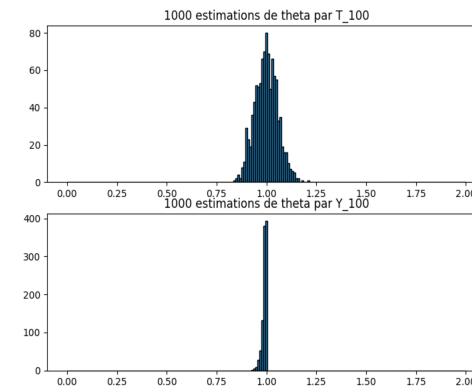
(b) Montrer que  $Y_n$  est un estimateur convergent de  $\theta$ . Cet estimateur est-il sans biais ?

(c) Comparer les estimateurs  $T_n$  et  $Y_n$ . Lequel est le plus pertinent ?

(d) Définir à partir de  $Y_n$  un estimateur sans biais de  $\theta$ , que l'on notera  $\beta_n$ .

4. Simulation informatique : le programme suivant permet d'effectuer 1000 simulations de  $T_{100}$  et  $Y_{100}$ , puis affiche les histogrammes des valeurs obtenues. On se place dans le cas où  $\theta = 1$ .

```
n=100
E = rd.random([1000,n]) # 1000 échantillons observés
T=np.zeros(1000) # estimateur T_n
Y=np.zeros(1000) # estimateur Y_n
for k in range(1000):
    E[k]=np.max(E[:,k])
    T[k]=2*np.mean(E[:,k])
    c = np.linspace(0,2,200)
    plt.subplot(2,1,1)
    plt.hist(T,c,edgecolor='k')
    plt.title('1000 estimations de theta par T_100')
    plt.subplot(2,1,2)
    plt.hist(Y,c,edgecolor='k')
    plt.title('1000 estimations de theta par Y_100')
plt.show()
```



Ceci confirme-t-il les résultats obtenus précédemment ?

## V. Intervalles de confiance

S'il existe des critères pour juger des qualités d'un estimateur ponctuel  $T_n$  de  $g(\theta)$ , aucune certitude ne peut jamais être apportée quand au fait que l'estimation est proche de la vraie valeur à estimer. La démarche de l'estimation par intervalle de confiance consiste à trouver un intervalle aléatoire qui contienne  $g(\theta)$  avec une probabilité minimale donnée.

### V.1 ) Définition

#### Définition V.1

Soit  $X$  une variable aléatoire qui suit une loi  $\mathcal{L}$  dépendant de  $\theta$ ; on cherche à connaître  $g(\theta)$ .

Soit  $(X_1, \dots, X_n)$  un  $n$ -échantillon i.i.d. issu de  $X$ . Soit  $\alpha \in ]0, 1[$  un réel fixé.

Soient  $U_n$  et  $V_n$  deux variables aléatoires fonctions de  $(X_1, \dots, X_n)$ .

On appelle **intervalle de confiance de  $g(\theta)$  au niveau de confiance  $1 - \alpha$**  (ou au **niveau de risque  $\alpha$** ) tout intervalle  $[U_n, V_n]$  vérifiant :

- $U_n \leq V_n$ .
- $U_n$  et  $V_n$  sont des estimateurs de  $g(\theta)$  dont l'expression ne dépend pas de  $\theta$ .
- $P(U_n \leq g(\theta) \leq V_n) \geq 1 - \alpha$ .

Toute réalisation de  $[U_n, V_n]$  est une estimation de cet intervalle de confiance.

#### Remarque

- Il n'y a pas unicité de  $U_n$  et  $V_n$  !!!

Par exemple si  $[U_n, V_n]$  est un intervalle de confiance au niveau de confiance  $1 - \alpha$ , il en est de même pour  $[U_n - 1, V_n + 1]$ , même si ce deuxième intervalle est moins intéressant.

- On parle d'intervalle de confiance de niveau de confiance  $1 - \alpha$ . En pratique, le risque  $\alpha$  sera petit et le niveau de confiance  $1 - \alpha$  sera "grand" c'est à dire proche de 1.

Par exemple :  $\alpha_1 = 0.05 = 5\%$  et  $1 - \alpha_1 = 0.95 = 95\%$

Ou  $\alpha_2 = 0.01 = 1\%$  et  $1 - \alpha_2 = 0.99 = 99\%$ .

- Souvent  $U_n$  et  $V_n$  sont construits à l'aide du même estimateur  $T_n$  de  $\theta$ .

- Le réel  $V_n - U_n$  est appelé amplitude ou étendue de l'intervalle de confiance (on cherche à le minimiser pour avoir un intervalle de confiance le plus précis possible).

#### Remarque

Supposons que  $U_n = \phi_n(X_1, X_2, \dots, X_n)$  et  $V_n = \psi_n(X_1, X_2, \dots, X_n)$ .

La réalisation observée  $x_1, \dots, x_n$  fournit l'**intervalle de confiance observé**  $[u_n, v_n]$  où  $u_n = \phi_n(x_1, x_2, \dots, x_n)$  et  $v_n = \psi_n(x_1, x_2, \dots, x_n)$ .

L'intervalle  $[u_n, v_n]$  est parfois appelé "fourchette".

### V.2 ) Intervalle de confiance du paramètre d'une loi de Bernoulli

Un bureau d'études teste une machine qui fabrique un certain type d'objets. En fonctionnement normal, elle produit des objets défectueux en proportion  $p \in ]0, 1[$  inconnue. Un étude cherche à estimer la valeur de  $p$ .

On prélève à la production un échantillon de  $n$  objets et on considère les variables de Bernoulli  $X_1, \dots, X_n$  où  $X_k = 1$ ssi le  $k$ -ième objet est défectueux.

Ces variables sont supposées indépendantes : il s'agit d'un  $n$ -échantillon i.i.d. de la loi  $B(p)$ .

On note :  $\bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k$ . Soit  $\alpha$  un réel de  $]0, 1[$ .

1. Montrer que pour tout  $x \in [0, 1]$ ,  $x(1-x) \leq \frac{1}{4}$  (à retenir et à savoir redémontrer rapidement).

2. Calculer l'espérance et la variance de  $\bar{X}_n$ .

3. Estimation ponctuelle

Justifier que  $\bar{X}_n$  est un estimateur sans biais et convergent de  $p$ .

4. Estimation par intervalle de confiance

(a) A l'aide de l'inégalité de Bienaymé-Tchebychev, montrer pour tout réel  $\epsilon$  strictement positif,

$$P(\bar{X}_n - \epsilon \leq p \leq \bar{X}_n + \epsilon) \geq 1 - \frac{p(1-p)}{n\epsilon^2}$$

(b) En déduire que :  $P\left(\bar{X}_n - \sqrt{\frac{p(1-p)}{n\alpha}} \leq p \leq \bar{X}_n + \sqrt{\frac{p(1-p)}{n\alpha}}\right) \geq 1 - \alpha$

(c) En déduire un intervalle de confiance de  $p$  à un niveau de confiance au moins égal à  $1 - \alpha$

5. Application numérique :

On a prélevé un échantillon de  $n = 1000$  objets et constaté que 10 d'entre eux étaient défectueux.

(a) Quelle estimation ponctuelle de  $p$  peut-on donner avec l'estimateur  $\bar{X}_n$  ?

(b) Déterminer une estimation de l'intervalle de confiance ci-dessus au niveau de confiance 0.95 ("fourchette").

#### Proposition V.1

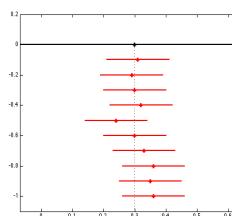
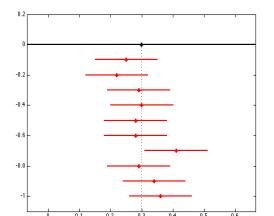
Soit  $X$  une variable aléatoire de Bernoulli de paramètre  $p$ .

On pose  $U_n = \bar{X}_n - \frac{1}{2\sqrt{n\alpha}}$  et  $V_n = \bar{X}_n + \frac{1}{2\sqrt{n\alpha}}$ .

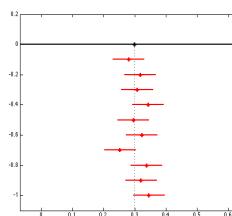
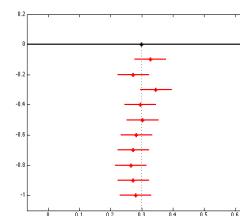
Alors  $[U_n, V_n]$  est un intervalle de confiance de  $p$  de risque  $\alpha$ .

**A savoir redémontrer**

Simulations pour  $\alpha = 0,25$  et  $n = 100$ .



Simulations pour  $\alpha = 0,25$  et  $n = 400$ .



### V.3 ) Intervalle de confiance de l'espérance d'une loi normale dont la variance est connue

Un autre bureau d'études teste des cables de téléphérique. En fonctionnement normal, la charge maximale (en tonnes)  $X$  supportée par le cable suit une loi normale de paramètre  $(m, \sigma^2)$ .

On suppose que la valeur de  $m$  est inconnue et que la valeur de  $\sigma^2$  est connue.

Une étude cherche à estimer la valeur de  $m$ . Pour cela, on teste successivement un échantillon aléatoire de  $n$  cables. On considère les variables  $X_1, \dots, X_n$  i.i.d. où  $X_k$  est la charge maximale supportée par le  $k$ -ième cable testé. Ces variables sont supposées indépendantes.

On note  $\forall n \in \mathbb{N}^*$   $\bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k$ .

#### 1. Estimation ponctuelle

Preciser  $E(\bar{X}_n)$  et  $V(\bar{X}_n)$ . Prouver que  $\bar{X}_n$  est un estimateur sans biais convergent de  $m$ .

#### 2. Estimation par intervalle de confiance

(a) Justifier que la variable aléatoire  $\bar{X}_n^* = \frac{\bar{X}_n - m}{\frac{\sigma}{\sqrt{n}}}$  suit une loi normale centrée réduite.

(b) Soit  $t \in ]0, +\infty[$ .

i. Justifier que :  $P(|\bar{X}_n^*| \leq t) = 2\Phi(t) - 1$  où  $\Phi$  est la fonction de répartition de la loi normale centrée réduite.

ii. En déduire que :  $P(\bar{X}_n - t\frac{\sigma}{\sqrt{n}} \leq m \leq \bar{X}_n + t\frac{\sigma}{\sqrt{n}}) = 2\Phi(t) - 1$ .

(c) Montrer qu'il existe un unique  $u_\alpha$  de  $\mathbb{R}$  tel que  $2\Phi(u_\alpha) - 1 = 1 - \alpha$ . Justifier que  $u_\alpha > 0$

(d) On note  $U_n = \bar{X}_n - u_\alpha \frac{\sigma}{\sqrt{n}}$  et  $V_n = \bar{X}_n + u_\alpha \frac{\sigma}{\sqrt{n}}$ .

Montrer que  $[U_n, V_n]$  est un intervalle de confiance de  $m$  au niveau de confiance  $1 - \alpha$ .

(e) En fait,  $\sigma$  est inconnu mais on sait que  $\sigma \leq 0.5$ . Donner un intervalle de confiance de  $m$  au niveau de confiance  $1 - \alpha$ .

#### 3. Application numérique ( $\Phi(2.58) = 0.995$ )

On sait que  $\sigma \leq 0.5$ . On a testé  $n = 50$  cables et la moyenne des charges maximales observées sur cet échantillon est 12.2 tonnes. Donner une estimation de l'intervalle de confiance (fourchette) de  $m$  au risque 0.01.

### V.4 ) Intervalle de confiance asymptotique

#### Définition V.2

Soit  $X$  une variable aléatoire qui suit une loi  $\mathcal{L}$  dont on cherche à connaître  $g(\theta)$ .

Soit  $(X_1, \dots, X_n)$  un échantillon i.i.d. de taille  $n$  issu de  $X$ .

Soient  $U_n$  et  $V_n$  deux variables aléatoires fonctions de  $(X_1, \dots, X_n)$ .

Soit  $\alpha \in ]0, 1[$  un réel fixé.

On appelle **intervalle de confiance asymptotique de  $g(\theta)$  au niveau de confiance  $1 - \alpha$**  tout intervalle  $[U_n, V_n]$  vérifiant

- $U_n \leq V_n$ .

- $U_n$  et  $V_n$  sont des estimateurs de  $g(\theta)$  dont l'expression ne dépend pas de  $g(\theta)$ .

- il existe une suite  $(\alpha_n)_{n \in \mathbb{N}^*}$  de réels vérifiant :

$$P(U_n \leq g(\theta) \leq V_n) \geq 1 - \alpha_n$$

où  $\lim_{n \rightarrow +\infty} (\alpha_n) = \alpha$

#### Remarque

Si  $[U_n, V_n]$  est un **intervalle de confiance asymptotique de  $\theta$  au niveau de confiance  $1 - \alpha$**  alors :

$$\lim_{n \rightarrow +\infty} \left( P(U_n \leq \theta \leq V_n) \right) \geq 1 - \alpha$$

#### Remarque

En pratique, on peut montrer que

$$\lim_{n \rightarrow +\infty} (P(U_n \leq \theta \leq V_n)) = 1 - \alpha$$

et alors  $[U_n, V_n]$  est un intervalle de confiance asymptotique de  $\theta$  au risque  $\alpha$ .

En effet, il suffit de poser  $\alpha_n = 1 - P(U_n \leq \theta \leq V_n)$  pour revenir à la définition.

### V.5 ) Intervalle de confiance asymptotique du paramètre $p$ d'une loi de Bernoulli

Soit  $(X_n)_{n \in \mathbb{N}^*}$  une suite de variables aléatoires indépendantes de même loi  $\mathcal{B}(p)$  où  $p \in ]0, 1[$ .

Soit  $\alpha \in ]0, 1[$ .

On note  $\bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k$ .

1. Rappel :  $\bar{X}_n$  est un estimateur sans biais convergent de  $p$  et  $E(\bar{X}_n) = p$  et  $V(\bar{X}_n) =$

2. Soit  $\Phi$  la fonction de répartition d'une variable suivant  $\mathcal{N}(0, 1)$ .  
Justifier qu'il existe un unique réel  $t_\alpha > 0$  tel que  $\Phi(t_\alpha) = 1 - \frac{\alpha}{2}$ .

3. (a) Justifier que

$$\lim_{n \rightarrow +\infty} P(\bar{X}_n - t_\alpha \cdot \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq p \leq \bar{X}_n + t_\alpha \cdot \frac{\sqrt{p(1-p)}}{\sqrt{n}}) = 1 - \alpha$$

(b) En déduire que

$$\lim_{n \rightarrow +\infty} P(\bar{X}_n - t_\alpha \cdot \frac{1}{2\sqrt{n}} \leq p \leq \bar{X}_n + t_\alpha \cdot \frac{1}{2\sqrt{n}}) \geq 1 - \alpha$$

En déduire un intervalle de confiance asymptotique de  $p$  au niveau de confiance  $1 - \alpha$ .

4. Application numérique :

On reprend l'exemple final du V.3

On donne  $\Phi(1.96) = 0.975$ . On a prélevé un échantillon de taille  $n = 1000$  et observé 10 objets sans défaut.

Donner une estimation de cet intervalle de confiance asymptotique au niveau de risque 0.05.

## VI. Méthode de Monte-Carlo

La **méthode de Monte-Carlo** permet d'obtenir par simulation une estimation ponctuelle d'un réel  $M$  s'exprimant comme l'espérance  $E(Y)$  d'une certaine variable aléatoire, ou comme une certaine probabilité.

Les outils sont :

- les lois usuelles (via `rd.random()` ou `rd.` .... en Python),
- le théorème de transfert
- L'utilisation de la moyenne empirique  $\bar{Y}_n = \frac{1}{n} \sum_{k=1}^n Y_k$  associée à une suite  $Y_1, Y_2, \dots$  de variables i.i.d. de même loi que  $Y$ . La moyenne empirique est un estimateur sans biais et convergent (loi faible des grands nombres) de  $E(Y)$ .

### Méthode VI.1

#### Méthode de Monte-Carlo (estimation d'une espérance)

1. On écrit à l'aide du théorème de transfert  $M = E(Y)$  avec  $Y = g(X)$ , où  $X$  est une variable aléatoire que l'on sait simuler.
2. On simule, pour  $n$  assez grand, un  $n$ -échantillon i.i.d.  $Y_1, \dots, Y_n$  de même loi que  $Y$ . On prend la valeur observée de  $\bar{Y}_n$  comme estimation de  $M$ .
3. En Python, on peut déclarer la fonction  $g$ , et utiliser `rd. ...., np.mean, np.sum`, boucle `for`...

#### Remarque

On peut être amené par l'énoncé à affiner par la mise en place d'un intervalle de confiance.

### Méthode VI.2

#### Méthode de Monte-Carlo (estimation d'une probabilité)

1. On reconnaît  $M = P(A)$ , où  $A$  est un événement souvent lié à une VAR  $X$ . On considère la VAR de Bernoulli  $Y$  indicatrice de l'événement  $A$  et on a  $M = E(Y)$ .
2. On simule, pour  $n$  assez grand, un  $n$ -échantillon i.i.d.  $Y_1, \dots, Y_n$  de même loi que  $Y$ . On prend la valeur observée de  $\bar{Y}_n$  comme estimation de  $M$ .
3. En Python, on utilise si possible `rd.random(n)`, ou `rd. ....(n)` (pour toute loi usuelle) pour générer directement les  $n$  valeurs de  $Y_1, \dots, Y_n$  (sinon boucle `for`). On compte le nombre de succès  $S_n$ , puis  $\bar{Y}_n = \frac{S_n}{n}$ .

#### Exemple

Un classique : méthode de Monte-Carlo pour trouver une valeur approchée de  $\pi$

On considère une cible carrée ABCD de côtés les points  $A(1, 1), B(-1, 1), C(-1, -1), D(1, -1)$  ainsi que le cercle unité  $C$  de centre  $O(0, 0)$  et de rayon 1.

1. Représenter le carré et le cercle dans le plan. Quelle est l'équation du cercle  $C$ ? A quelle condition un point  $M(x, y)$  est-il à l'intérieur du cercle  $C$ ?
2. On effectue une succession de lancers d'une fléchette. On suppose que les lancers sont indépendants, que chaque lancer atteint la cible carrée, de façon aléatoire, c'est-à-dire que l'abscisse  $X$  et l'ordonnée  $Y$  d'une fléchette sont des variables aléatoires indépendantes suivant la loi uniforme  $\mathcal{U}([-1, 1])$ .  
Quelle est la probabilité qu'une fléchette soit à l'intérieur du cercle?
3. En déduire un programme `MonteCarloPi(n)` : qui simule  $n$  lancers de fléchettes, calcule la fréquence avec laquelle on atteint l'intérieur du cercle, et retourne une valeur approchée de  $\pi$ . Exécuter ce programme pour  $n = 1000$ , pour  $n = 100000$ , pour  $n = 10000000$ .  
Que peut-on dire quand à cette méthode?
4. Une méthode déterministe : on sait que  $\sum_{k=1}^{\infty} \frac{1}{k^2} = \frac{\pi^2}{6}$ . En déduire une autre méthode de calcul d'une valeur approchée de  $\pi$  et taper le programme correspondant. Comparer les temps de calcul.

**Exercice 3.1**  
Soit  $M = \int_0^{+\infty} \frac{4}{1+t^2} dt$ .

1. Ecrire  $M$  comme l'espérance d'une variable aléatoire  $Y$ . Justifier que  $V(Y)$  existe et  $V(Y) \leq 16$ .
2. (a) Ecrire un programme Python, qui définit la fonction  $g$  où  $g(t) = \frac{4}{1+t^2}$  puis qui affiche une estimation de  $M$  par la méthode de Monte-Carlo pour un échantillon de taille  $n$ .  
(b) Calculer la valeur exacte de  $M$ .  
Comparer avec les résultats obtenus précédemment.

#### Exercice 4

De quel réel le résultat affiché par le script Python ci-dessous devrait-il être proche pour  $n$  suffisamment grand ?

```
n=int(input('n='))  
Y=rd.exponential(3,n)  
M=np.mean(np.exp(-Y))  
print(M)
```

#### Exercice 5

Dans chaque cas, justifier la convergence de l'intégrale puis écrire un programme utilisant la méthode de Monte-Carlo qui permet d'obtenir une estimation ponctuelle de  $M$ .

$$1. M = \int_0^{+\infty} \sin(t).e^{-2t} dt$$

Adapter le programme pour estimer  $M_1 = \int_1^{+\infty} \sin(t).e^{-2t} dt$

$$2. M = \int_0^{+\infty} \frac{e^{-t^2}}{1+t^2} dt.$$

#### Exercice 6

##### Extrait Edhec 2017

On peut montrer par un changement de variables que

$$I(x) = \int_x^{+\infty} t^k.e^{-t} dt = e^{-x}. \int_0^{+\infty} (u+x)^k.e^{-u} du$$

Compléter le script suivant pour qu'il calcule une estimation de  $I(x)$  par la méthode de Monte-Carlo.

```
x=float(input('x='))  
k=int(input('k='))  
Z=rd.exp(1,100000)  
s=np.exp(-x)*np.mean(.....)  
print(s)
```

#### Exercice 7

Dans chaque cas, écrire  $M$  comme l'espérance d'une certaine variable aléatoire, puis écrire un programme Python pour déterminer, via la méthode de Monte-Carlo, une estimation ponctuelle de  $M$ .

$$1. M = \sum_{k=1}^{+\infty} \frac{1}{k^2.2^k}$$

$$2. M = \sum_{k=0}^{+\infty} \frac{\sqrt{k}}{k!}$$

$$3. M = \sum_{k=0}^{10} \frac{\binom{10}{k}}{k^2 + 1}$$