

ESTIMATION

*Donner une valeur approchée aux paramètres d'une population (μ , σ^2 , ...)
à l'aide d'un échantillon de cette population*

Hypothèse de l'échantillonnage : Les observations x_1, \dots, x_n
sont considérées comme des réalisations de X_1, \dots, X_n v.a.i.i.d.

Un estimateur T_n est une variable
aléatoire fonction de X_1, \dots, X_n
$$T_n = f(X_1, \dots, X_n)$$

Exemples : moyenne, variance empirique, ...

Pour un même paramètre, il peut y avoir plusieurs
estimateurs possibles. Lequel choisir?

➔ Qualité d'un estimateur

ESTIMATION

Exemple

Soit X le temps d'attente entre deux atterrissages sur un aéroport. On peut supposer que X suit une loi exponentielle car temps d'attente. Reste à estimer le paramètre θ d'après les observations

x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9
0.4	1	0.5	0.3	0.1	0.2	1.4	0.2	0.5

On sait $E(X)=1/\theta$ et $var(X)=1/\theta^2$. Donc deux possibilités pour estimer θ

Espérance ➔ $\theta=1.96$

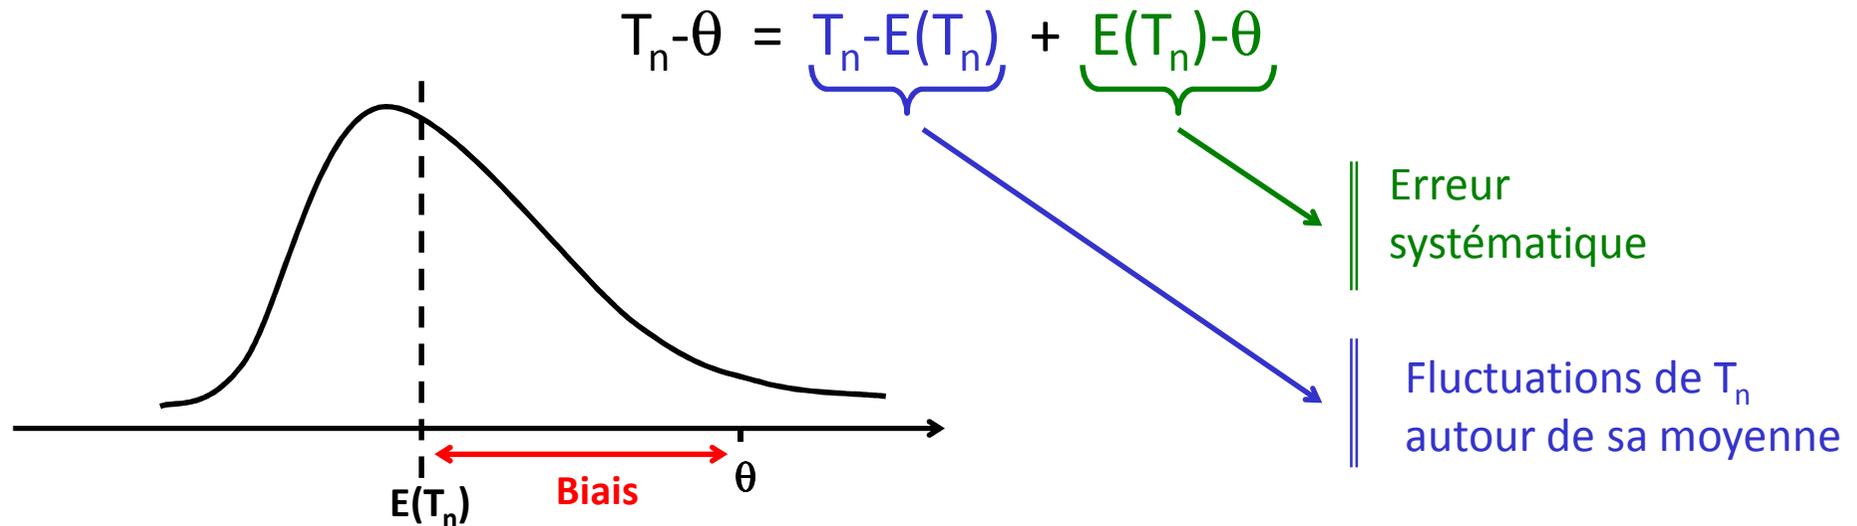
Variance ➔ $\theta=2.35$

?

Sert ensuite à mieux gérer le temps des contrôleurs

QUALITE D'UN ESTIMATEUR

Soit θ le paramètre à estimer et T_n un estimateur de θ . On étudie l'écart $T_n - \theta$



➤ La constante $b = E(T_n) - \theta$ est appelé le biais de l'estimateur et on dit que l'estimateur est sans biais si $E(T_n) = \theta$.

Exemple : Si l'échantillon suit une loi $\mathcal{P}(\lambda)$ alors la moyenne est un estimateur sans biais de λ .

QUALITE D'UN ESTIMATEUR

Convergence de l'estimateur

⇔ Améliorer l'estimation quand la taille de l'échantillon augmente

- La loi des grands nombres permet dans certains cas d'établir la convergence en probabilité

$$T_n \xrightarrow[n \rightarrow \infty]{p} \theta$$

- La précision de l'estimateur est mesurée par l'erreur quadratique moyenne :

$$R_{\theta}(T_n) = E[(T_n - \theta)^2] = \text{var}(T_n) + b^2$$

Il faut que la précision augmente avec la taille de l'échantillon, i.e $R_{\theta}(T_n) \xrightarrow[n \rightarrow \infty]{} 0$

L'estimateur T_1 est **meilleur** que l'estimateur T_2 si

$$E[(T_1 - \theta)^2] \leq E[(T_2 - \theta)^2] \Leftrightarrow R_{\theta}(T_1) \leq R_{\theta}(T_2)$$

Si estimateurs sans biais, le meilleur est celui de variance minimale

Exemple : Dans le cas où l'échantillon suit une loi de $\mathcal{P}(\lambda)$ alors la moyenne converge en probabilité vers λ et le risque quadratique converge vers 0. On note que la moyenne est un meilleur estimateur de λ que l'estimateur donné par X_1

QUALITE D'UN ESTIMATEUR

Loi asymptotique de l'estimateur

- Le TCL permet dans certains cas d'établir la convergence en loi de l'estimateur

$$T_n \xrightarrow[n \rightarrow \infty]{\mathcal{L}} N(*, *)$$

Connaître la loi de l'estimateur permet de calculer des probabilités sur l'estimateur

Exemple : Dans le cas où l'échantillon suit une loi de $\mathcal{P}(\lambda)$ alors l'estimateur donné par la moyenne converge en loi

$$\sqrt{n} \frac{\bar{X} - \lambda}{\sqrt{\lambda}} \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} N(0,1)$$

On en déduit par exemple la probabilité d'une précision fixée par ε

$$P(|\bar{X} - \lambda| \leq \varepsilon) = 2F\left(\varepsilon \sqrt{\frac{n}{\lambda}}\right) - 1$$

où F est la fonction de répartition de la loi N(0,1)

ESTIMATEUR USUEL

La fréquence

Soit un événement A tel que $P(A)=p$. Sur un échantillon considérons les v.a.

X_1, \dots, X_n telles que $X_i = \begin{cases} 1 & \text{si A est réalisé} \\ 0 & \text{sinon} \end{cases}$. Alors la **fréquence** (empirique) de

l'événement A est définie par

$$F_n = \frac{1}{n} \sum_{i=1}^n X_i = \frac{K}{n}$$

où K représente le nombre de fois où l'événement A s'est réalisé au cours des n expériences.

- sans biais : $E(F_n) = p$

- converge en probabilité

- converge en m.q. tel que

- loi asymptotique :

$$R_p(F_n) = \frac{p(1-p)}{n}$$

$$F_n \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} N\left(p, \frac{p(1-p)}{n}\right)$$

Exemple : Une machine fabrique des pièces et le cahier des charges de la machine précise un taux de 10% de pièces défectueuses. On effectue un contrôle. Si la machine est en bon état de fonctionnement, combien faut-il vérifier de pièces pour avoir un taux de pièces défectueuses observé inférieur à 15% avec une probabilité de 95%?

ESTIMATEUR USUEL

La moyenne

La **moyenne** (empirique) de l'échantillon X_1, \dots, X_n est la v.a. définie par

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

Rq. La fréquence est une moyenne d'un échantillon de Bernoulli

Supposons que $E(X_i) = \mu$ et $\text{var}(X_i) = \sigma^2$, alors

- sans biais : $E(\bar{X}) = \mu$

- converge en probabilité

- converge en m.q. tel que

- loi asymptotique :

$$R_{\mu}(\bar{X}) = \frac{\sigma^2}{n}$$

$$\bar{X} \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} N\left(\mu, \frac{\sigma^2}{n}\right)$$

Exemple : On prélève 40 pièces dans une production industrielle. Le cahier des charges de la machine stipule que les pièces sont produites avec un diamètre d'espérance 20 mm et un écart-type de 3 mm. Toutes les pièces ayant un diamètre moyen supérieur à 21 ou inférieur à 19 sont inutilisables. Quel est le pourcentage de pièces prélevées utilisables?

ESTIMATEUR USUEL

La variance empirique

La **variance empirique** de l'échantillon X_1, \dots, X_n est la v.a. définie par

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

Supposons que $E(X_i) = \mu$ et $\text{var}(X_i) = \sigma^2$, alors

- biaisé : $E(S^2) = \frac{n-1}{n} \sigma^2$
- converge en probabilité
- $\Rightarrow S^{*2} = \frac{n}{n-1} S^2$ sans biais
- risque quadratique et loi asymptotique inconnus

Exemple : On prélève 40 pièces dans une production industrielle. Le cahier des charges de la machine stipule que le diamètre des pièces suit une loi normale d'espérance 20mm et d'écart-type 2 mm. On considère que la production n'est plus homogène (disparité importante entre les pièces) lorsque l'écart-type empirique dépasse de 5% sa valeur théorique. Quelle est la probabilité que la production ne soit plus homogène ?

ESTIMATEUR USUEL

Echantillon gaussien

Dans le cas d'un échantillon X_1, \dots, X_n gaussien, *i.e* $X_i \sim N(\mu, \sigma^2)$, on connaît la loi exacte des estimateurs usuels de μ et σ^2 . Il est donc possible de travailler avec des échantillons de petite taille

Estimation de μ	<ul style="list-style-type: none"> ▪ σ^2 connu, $\theta = \mu \Rightarrow \sqrt{n} \frac{\bar{X} - \theta}{\sigma} \sim N(0,1)$ ▪ σ^2 inconnu, $\theta = \mu \Rightarrow \sqrt{n} \frac{\bar{X} - \theta}{S^*} \sim t_{(n-1)}$ (Loi de Student)
	<ul style="list-style-type: none"> ▪ μ connu, $\theta = \sigma^2 \Rightarrow \frac{1}{\theta} \sum_{i=1}^n (X_i - \mu)^2 \sim \chi_n^2$ (Loi du chi-deux) ▪ μ inconnu, $\theta = \sigma^2 \Rightarrow \frac{1}{\theta} \sum_{i=1}^n (X_i - \bar{X})^2 \sim \chi_{n-1}^2 \Leftrightarrow \frac{(n-1)}{\theta} S^{*2} \sim \chi_{n-1}^2$

On sait aussi que la variance empirique S^{*2} converge en m.q.

Exemple : Une machine fabrique des pièces dont le diamètre suit une loi normale $N(20, 2^2)$. On prélève 9 pièces dans la production.

Quelle est la probabilité pour que le diamètre moyen des 9 pièces soit inférieur à 18?

Quelle est la probabilité pour que l'écart-type soit supérieur à 2,5?

Estimation par I.D.C.

Estimateur d'un paramètre θ = variable aléatoire



Incertitude sur la
valeur estimée

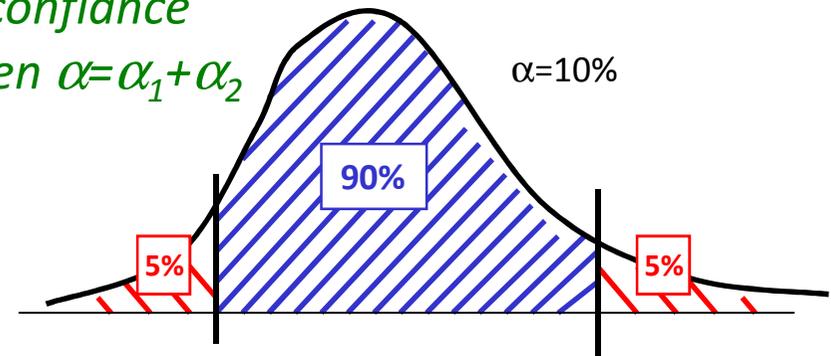
Intervalle de confiance est un intervalle dans lequel on peut supposer que le paramètre θ se trouve avec une probabilité d'erreur fixée par l'utilisateur :

$$P[a \leq \theta \leq b] = 1 - \alpha$$

où α est le niveau de confiance

Les bornes de l'intervalle de confiance dépendent du partage de α en $\alpha = \alpha_1 + \alpha_2$

- Intervalle bilatéral : $[a, b]$.
On utilise en général le **risque symétrique**, i.e
 $\alpha_1 = \alpha_2 = \alpha/2$



- Intervalle unilatéral
 - $[a, +\infty[$ (i.e. $\alpha_1 = \alpha, \alpha_2 = 0$) utiliser dans le cas où le paramètre θ doit vérifier $\theta \geq a$ (durée de vie, résistance à la rupture, etc...)
 - $]-\infty, b]$ (i.e. $\alpha_1 = 0, \alpha_2 = \alpha$) utiliser dans le cas où le paramètre θ doit vérifier $\theta \leq b$ (nombre de pièces défectueuses, temps d'attente, etc...)

Estimation par I.D.C.

Méthodologie

- Définir un estimateur $T_n = f(X_1, \dots, X_n)$ de θ
- Déterminer la loi de l'estimateur
- Transformer l'équation

$$P[a \leq \theta \leq b] = 1 - \alpha \Leftrightarrow P[a' \leq T_n \leq b'] = 1 - \alpha$$

- Trouver a' et b' grâce à la table de la loi de l'estimateur
(1 équation et 2 inconnues \Rightarrow faire un dessin pour simplifier le problème)
- En déduire a et b

Exemple : Supposons $X \sim N(\mu, 1)$. On cherche un intervalle de confiance pour μ à 95%.

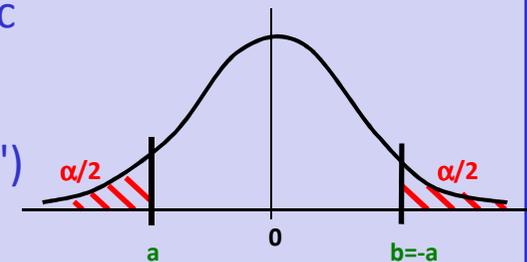
\bar{X} est un estimateur de μ et on sait que $\sqrt{n}(\bar{X} - \mu) \sim N(0, 1)$ donc

$$\begin{aligned} P[a \leq \mu \leq b] &= P[\sqrt{n}(\bar{x} - b) \leq \sqrt{n}(\bar{X} - \mu) \leq \sqrt{n}(\bar{x} - a)] \\ &= F(\sqrt{n}(\bar{x} - a)) - F(\sqrt{n}(\bar{x} - b)) = F(a') - F(b') \end{aligned}$$

Risque symétrique et loi $N(0, 1)$ symétrique /r à Oy $\Rightarrow a' = -b'$

$$P[a \leq \mu \leq b] = 0.95 \Leftrightarrow 2F(a') - 1 = 0.95 \Leftrightarrow F(a') = 0.975 \Leftrightarrow a' = 1.96$$

$$\Rightarrow a = \bar{x} - \frac{a'}{\sqrt{n}} = \bar{x} - \frac{1.96}{\sqrt{n}} \quad \text{et} \quad b = \bar{x} + \frac{a'}{\sqrt{n}} = \bar{x} + \frac{1.96}{\sqrt{n}}$$



Attention de ne pas confondre l'IDC, $P[a \leq \theta \leq b] = 1 - \alpha$, et l'intervalle de probabilité $P[a \leq T_n \leq b] = 1 - \alpha$

Estimation par I.D.C.

Taille de l'échantillon

Le calcul d'un I.D.C. $[a,b]$ tel que $P[a \leq \theta \leq b] = 1 - \alpha$ dépend

- de l'estimateur de θ (\bar{X} , S^2, \dots)
- des quantiles de la loi (obtenus dans les tables)
- de la taille de l'échantillon n

Il est alors possible de déterminer la taille n telle que la longueur de l'intervalle $\ell = b - a$ vérifie une propriété donnée.

Exemple : Un laborantin utilise un thermomètre sophistiqué mais dont les mesures sont incertaines. On sait que l'écart-type de l'appareil est de 1.1 degré Celsius. Combien doit-il effectuer de mesures pour connaître avec un coefficient de confiance de 95%, la température moyenne à 0.5 degré près ?