

Remarques initiales :

Echantillonnage – Intervalle de fluctuation :

On utilise un *intervalle de fluctuation* quand :

- On connait la proportion p de présence du caractère dans la population
Ou bien si
- On fait une hypothèse sur la valeur de cette proportion (situation de « prise de décision »)

Estimation – Intervalle de confiance :

On utilise un *intervalle de confiance* quand :

- On ignore la proportion p de présence du caractère dans la population, sans faire d'hypothèse sur cette valeur.
-

Exemple 1 :

On dispose d'une pièce de monnaie, dont on cherche à savoir si elle est équilibrée ou pas.

On fait l'hypothèse d'une apparition de « Pile » égale à 0,5, que l'on va ensuite tester.

On est dans une situation d'échantillonnage.

Exemple 2 :

Une usine fabrique des appareils photographiques. Sur 1.000 appareils fabriqués, on constate que 15 d'entre eux ne fonctionnent pas. On cherche à évaluer la proportion d'appareils défectueux dans l'ensemble de la production.

On ne connaît pas au départ cette proportion, et on n'en fait pas d'hypothèse.

On est en situation d'estimation.

Echantillonnage – Intervalle de fluctuation de f au seuil de 95% :

Soit f la fréquence observée f dans l'échantillon :

- Si f appartient à l'intervalle de fluctuation au seuil de 95%, on accepte l'hypothèse,
- Si f n'appartient pas à l'intervalle de fluctuation, on rejette l'hypothèse, avec 5% de risque de rejeter une hypothèse pourtant vraie.

Connaissances niveau Seconde :

Si des échantillons de taille individuelle $n \geq 25$ relèvent du schéma de Bernoulli (loi binomiale) de probabilité p , telle que $0,2 \leq p \leq 0,8$, alors pour environ 95% des échantillons, la fréquence d'apparition de l'évènement X

appartient à l'intervalle $\left[p - \frac{1}{\sqrt{n}} ; p + \frac{1}{\sqrt{n}} \right]$.

Connaissances niveau Première :

Si la variable aléatoire X suit la loi binomiale $B(n ; p)$, alors environ 95% des valeurs possibles de la fréquence de

X , $f = \frac{X}{n}$, appartiennent à l'intervalle $\left[\frac{k_1}{n} ; \frac{k_2}{n} \right]$, avec $\begin{cases} k_1 \text{ plus petit entier } k \text{ tel que } p(X \leq k) > 0,025 \\ k_2 \text{ plus petit entier } k \text{ tel que } p(X \leq k) \geq 0,975 \end{cases}$.

Connaissances niveau Terminale (Intervalle de fluctuation asymptotique au seuil de 95%) :

Si la variable aléatoire X_n suit la loi binomiale $B(n; p)$, l'intervalle $I_n = \left[p - 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}} ; p + 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}} \right]$ est appelé intervalle de fluctuation asymptotique au seuil de 95%. C'est-à-dire que : $\lim_{n \rightarrow +\infty} p\left(\frac{X_n}{n} \in I_n\right) = 0,95$.

(Conditions nécessaires : $n \geq 30$, $np \geq 5$, $n(1-p) \geq 5$). On pose $Z = \frac{X_n - \mu}{\sigma} = \frac{X_n - np}{np(1-p)}$, avec $Z = N(0; 1)$.

On considère que la limite est atteinte dès que les conditions nécessaires sont satisfaites.

On peut alors écrire : $\text{Prob}\left(p - 1,96 \cdot \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq \frac{X_n}{n} \leq p + 1,96 \cdot \frac{\sqrt{p(1-p)}}{\sqrt{n}}\right) = 0,95$ ($u_{0,05} = 1,96$).

Une population présente un caractère avec une probabilité p , et tout échantillon extrait de cette population présente ce caractère avec une fréquence observée $f_{obs} = \frac{X_n}{n}$, qui fluctue autour de p .

95% des échantillons fluctuent dans l'intervalle précédent, mais 5% d'entre eux, bien que de cette population, peuvent fluctuer de plus. On peut alors douter de l'appartenance de l'échantillon à la population, mais avec un risque d'erreur de 5%.

Plus généralement : Intervalle de fluctuation asymptotique au seuil de $1 - \alpha$:

Si la variable aléatoire X_n suit la loi binomiale $B(n; p)$, pour tout réel $\alpha \in]0; 1[$:

u_α désigne le réel tel que $p(-u_\alpha \leq Z \leq u_\alpha) = 1 - \alpha$ lorsque $Z = N(0; 1)$.

L'intervalle $I_n = \left[p - u_\alpha \cdot \frac{\sqrt{p(1-p)}}{\sqrt{n}} ; p + u_\alpha \cdot \frac{\sqrt{p(1-p)}}{\sqrt{n}} \right]$ est appelé intervalle de fluctuation asymptotique au seuil

de $1 - \alpha$. C'est-à-dire que : $\lim_{n \rightarrow +\infty} p\left(\frac{X_n}{n} \in I_n\right) = 1 - \alpha$.

On considère que la limite est atteinte dès que les conditions nécessaires sont satisfaites.

On peut alors écrire : $\text{Prob}\left(p - u_\alpha \cdot \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq \frac{X_n}{n} \leq p + u_\alpha \cdot \frac{\sqrt{p(1-p)}}{\sqrt{n}}\right) = 1 - \alpha$.

Estimation – Intervalle de confiance de p au niveau de confiance de 95% :

On rappelle que si la variable aléatoire X_n suit la loi binomiale $B(n; p)$, et que $F_n = \frac{X_n}{n}$ est la fréquence constatée associée à X_n , alors, pour n assez grand, l'intervalle aléatoire $\left[F_n - \frac{1}{\sqrt{n}} ; F_n + \frac{1}{\sqrt{n}}\right]$ contient p avec une probabilité supérieure ou égale à 95%.

On réalise une expérience aléatoire n fois et on appelle f la fréquence observée d'apparition du caractère étudié.

L'intervalle $\left[f - \frac{1}{\sqrt{n}} ; f + \frac{1}{\sqrt{n}}\right]$ est appelé intervalle de confiance de p au niveau de confiance 0,95, où p est la proportion inconnue d'apparition du caractère dans la population. (Conditions nécessaires : $n \geq 30$, $np \geq 5$, $n(1-p) \geq 5$).

Taille minimale de l'échantillon pour obtenir une précision donnée :

L'intervalle de confiance $\left[f - \frac{1}{\sqrt{n}} ; f + \frac{1}{\sqrt{n}}\right]$ est de largeur $\frac{2}{\sqrt{n}}$. Plus n est grand, plus cet intervalle est précis.

Si l'on souhaite situer p dans un intervalle de largeur donnée a , il faut $\frac{2}{\sqrt{n}} \leq a$, soit $n \geq \frac{4}{a^2}$.

On remarquera que pour resserrer l'intervalle, il faut grandement augmenter la taille de l'échantillon (carré).