

I. Principe de l'échantillonnage et de l'estimation

On illustre la situation ainsi : on dispose d'une grande urne où se trouvent un très grand nombre de boules rouges et bleues.

Cas 1 : la proportion p des boules rouges est connue	Cas 2 : la proportion p des boules rouges n'est pas connue
On tire au hasard avec remise n boules de l'urne. On obtient donc une fréquence f de boules rouges sur cet échantillon. On s'attend à ce que la fréquence f observée soit « proche » de p , fréquence théorique. On est ici dans le cadre d'un échantillonnage .	On veut donc estimer la proportion p de boules rouges dans l'urne. Comme il y en a beaucoup, on ne peut pas toutes les compter. On tire donc au hasard avec remise n boules de l'urne. On obtient donc une fréquence f de boules rouges sur cet échantillon. On s'attend à ce que la fréquence p théorique soit « proche » de f , fréquence observée. On est ici dans le cadre d'une estimation .

II. Intervalles de fluctuation et de confiance

II.1. Calcul des intervalles de fluctuation et de confiance

Cas 1 : Échantillonnage	Cas 2 : Estimation
On connaît p , fréquence théorique d'un caractère sur une population. On a un échantillon de taille n . L'intervalle $\left[p - \frac{1}{\sqrt{n}}; p + \frac{1}{\sqrt{n}} \right]$ est appelée intervalle de fluctuation au seuil 95% de la fréquence de ce caractère aléatoire de taille n issu de la population. <u>Condition de validité :</u> $n \geq 30$, $np \geq 5$ et $n(1-p) \geq 5$.	On connaît f , fréquence observée d'un caractère sur un échantillon de taille n d'une population. $\left[f - \frac{1}{\sqrt{n}}; f + \frac{1}{\sqrt{n}} \right]$ est appelé intervalle de confiance au seuil 95% de la proportion p de ce caractère aléatoire de la population.

II.2. Signification des intervalles

Cas 1 : Échantillonnage	Cas 2 : Estimation
La fréquence observée f sur un échantillon de taille n appartient à l'intervalle de fluctuation au seuil 95% dans 95% des cas.	Au moins 95% des intervalles de confiance au seuil 95% contiennent la fréquence théorique p .

Exemples :

- On considère une pièce de monnaie équilibrée. La fréquence théorique (ou probabilité) de l'issue « Pile » est $p = 0,5$. Imaginons qu'on lance cette pièce 10000 fois; on obtiendrait un échantillon de taille $n = 10000$. Comme $n \geq 30$, $np = 5000 \geq 5$ et $n(1-p) = 5000 \geq 5$, on peut calculer l'intervalle de fluctuation au seuil 95% du caractère « Pile » :

$$\left[p - \frac{1}{\sqrt{n}}; p + \frac{1}{\sqrt{n}} \right] = \left[0,5 - \frac{1}{\sqrt{10000}}; 0,5 + \frac{1}{\sqrt{10000}} \right] = [0,49; 0,51]$$

Il y a donc 95% de chance que la fréquence observée de l'issue « Pile » sur un échantillon de taille 10000 appartienne à cet intervalle.

— On dispose d'une pièce de monnaie que l'on sait truquée. On veut estimer la probabilité p de l'issue « Pile » pour cette pièce.

On procède à 10000 tirages. La fréquence observée sur cet échantillon de taille $n = 10000$ de l'issue « Pile » est $f = 0,423$.

On calcule l'intervalle de confiance au seuil 95 % :

$$\left[f - \frac{1}{\sqrt{n}}; f + \frac{1}{\sqrt{n}} \right] = \left[0,423 - \frac{1}{\sqrt{10000}}; 0,423 + \frac{1}{\sqrt{10000}} \right] = [0,413; 0,433]$$

Il y a donc 95% de chance que la probabilité p de l'issue « Pile » appartienne à cet intervalle.

II.3. Prise de décision à partir d'un échantillon

◆ Propriété 1.

On considère une population dans laquelle on suppose que la proportion d'un caractère est p . On observe sur un échantillon de taille n une fréquence f du caractère.

On veut tester l'hypothèse : « La proportion de ce caractère dans la population est p ». Si I est l'intervalle de fluctuation au seuil 95% (en respectant les conditions de validité), la règle de décision est la suivante :

- Si $f \in I$, on considère que l'hypothèse selon laquelle la proportion est p dans la population n'est pas remise en question (et on l'accepte au seuil de confiance 95%).
- Si $f \notin I$, on rejette l'hypothèse selon laquelle cette proportion est p au seuil de confiance 95% (au risque de se tromper dans 5% des cas).

Exemple : L'entreprise A annonce que le pourcentage de moteurs défectueux dans la production est égal à 1%. Afin de vérifier cette affirmation 800 moteurs sont prélevés au hasard. On constate que 15 moteurs sont détectés défectueux. Le résultat de ce test remet-il en question l'annonce de l'entreprise A? Justifier. On pourra s'aider d'un intervalle de fluctuation.

Solution : Pour une proportion p et un échantillon de taille n , l'intervalle de fluctuation asymptotique au seuil de 95 % est :

$$\left[p - \frac{1}{\sqrt{n}}; p + \frac{1}{\sqrt{n}} \right]$$

sous les trois conditions : $n \geq 30$, $np \geq 5$ et $n(1-p) \geq 5$.

L'échantillon de l'enquête est de taille $n = 800$ et l'entreprise annonce que le pourcentage de moteurs défectueux est égal à 1 % donc $p = 0,01$.

Regardons si les trois conditions sont vérifiées :

$$n = 800 \geq 30, np = 800 \times 0,01 = 8 \geq 5 \text{ et } n(1-p) = 800 \times 0,99 = 792 \geq 5.$$

$$\text{L'intervalle est : } I = \left[0,01 - \frac{1}{\sqrt{800}}; 0,01 + \frac{1}{\sqrt{800}} \right] \approx [0,003; 0,017].$$

On constate que 15 moteurs sont détectés défectueux sur 800, ce qui fait une proportion de $\frac{15}{800} = 0,01875$; or $0,01875 \notin I$ donc le résultat de ce test remet en question l'annonce de l'entreprise A.