

Chapitre 16: Fluctuation et estimation

1 Intervalle de fluctuation

Dans une urne contenant 4 boules bleues et 6 boules rouges, on effectue 100 tirages avec remise et on s'intéresse à la fréquence f d'apparition d'une boule bleue. On a ainsi réalisé un échantillon de taille $n = 100$.

1.1 Loi binomiale

En classe de première, on a associé à l'échantillon de taille n la variable aléatoire X_n qui donne le nombre de fois où une boule bleue est apparue. Comme les tirages sont indépendants, X_n suit une loi binomiale $\mathcal{B}(n, p)$ où $n = 100$ et $p = 0,4$ pour notre exemple. En posant $F_n = \frac{X_n}{n}$ la fréquence d'apparition de la boule bleue, on va déterminer un intervalle de la forme $\left[\frac{a}{n}; \frac{b}{n}\right]$ avec a et b les plus petites entiers tels que $P(X_n \leq a) > 0,025$ et $P(X_n \leq b) \geq 0,975$. Cette intervalle vérifie

$$P\left(F_n \in \left[\frac{a}{n}; \frac{b}{n}\right]\right) \geq 0,95$$

est appelé intervalle de fluctuation au seuil de 0,95 de F_n .

Ainsi, à l'aide du tableur on obtient pour notre exemple que $a = 31$ et $b = 50$ donc lorsque l'on réalise un échantillon de taille $n = 100$, la fréquence f d'apparition d'une boule bleue appartient à l'intervalle de fluctuation $[0,31; 0,5]$ avec une probabilité de 0,95.

1.2 Théorème de Moivre-Laplace

Soit $\alpha \in]0; 1[$ et u_α le réel tel que $P(-u_\alpha \leq Z \leq u_\alpha) = 1 - \alpha$ où Z suit la loi normale centrée réduite $\mathcal{N}(0, 1)$. D'après le théorème de Moivre-Laplace, si X_n suit une loi binomiale $\mathcal{B}(n, p)$ alors :

$$\lim_{n \rightarrow +\infty} P\left(-u_\alpha \leq \frac{X_n - np}{\sqrt{np(1-p)}} \leq u_\alpha\right) = P(-u_\alpha \leq Z \leq u_\alpha) = 1 - \alpha$$

or

$$-u_\alpha \leq \frac{X_n - np}{\sqrt{np(1-p)}} \leq u_\alpha \iff -u_\alpha \sqrt{np(1-p)} \leq X_n - np \leq u_\alpha \sqrt{np(1-p)} \iff p - u_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq \frac{X_n}{n} \leq p + u_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}}$$

On en déduit le théorème et la définition suivante :

Théorème:

Soit X_n une variable aléatoire suivant la loi binomiale $\mathcal{B}(n, p)$ et $F_n = \frac{X_n}{n}$.

Soit $\alpha \in]0; 1[$ et u_α le réel tel que $P(-u_\alpha \leq Z \leq u_\alpha) = 1 - \alpha$ où Z suit la loi normale centrée réduite $\mathcal{N}(0, 1)$ alors :

$$\lim_{n \rightarrow +\infty} P(F_n \in I_n) = 1 - \alpha$$

où

$$I_n = \left[p - u_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}}; p + u_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} \right]$$

Définition:

Sous les conditions énoncées dans le théorème ci-dessus, on dit que l'intervalle I_n est un intervalle de fluctuation asymptotique de la variable aléatoire fréquence $F_n = \frac{X_n}{n}$ au seuil de $1 - \alpha$. Ainsi, pour n grand, la variable aléatoire F_n prend ses valeurs dans l'intervalle I_n avec une probabilité proche de $1 - \alpha$. En pratique, on utilise cet intervalle de fluctuation de F_n dès que

$$n \geq 30 \quad ; \quad np \geq 5 \quad ; \quad n(1-p) \geq 5$$

Exemple:

Avec l'exemple initiale, si $\alpha = 0,05$, on a $u_{0,05} \simeq 1,96$ et donc :

$$I_{100} = \left[0,4 - 1,96 \frac{\sqrt{0,4 \times 0,6}}{\sqrt{100}}; 0,4 + 1,96 \frac{\sqrt{0,4 \times 0,6}}{\sqrt{100}} \right] = [0,303; 0,497]$$

$[0,303; 0,497]$ est intervalle de fluctuation asymptotique de la variable aléatoire fréquence au seuil de 0,95. Lorsque l'on réalise un échantillon de taille $n = 100$, la fréquence f d'apparition d'une boule bleue appartient à cet intervalle avec une probabilité de 0,95.

Si $\alpha = 0,01$, on a $u_{0,01} \simeq 2,58$ et donc :

$$I_{100} = \left[0,4 - 2,58 \frac{\sqrt{0,4 \times 0,6}}{\sqrt{100}}; 0,4 + 2,58 \frac{\sqrt{0,4 \times 0,6}}{\sqrt{100}} \right] = [0,273; 0,527]$$

$[0,273; 0,527]$ est intervalle de fluctuation asymptotique de la variable aléatoire fréquence au seuil de 0,99. Lorsque l'on réalise un échantillon de taille $n = 100$, la fréquence f d'apparition d'une boule bleue appartient à cet intervalle avec une probabilité de 0,99.

2 Prise de décision

On souhaite savoir si un pièce est équilibrée, au seuil de décision de 5%, sachant qu'en la lançant 100 fois on a obtenu 40 pile. La proportion de pile supposée (puisqu'on émet l'hypothèse « la pièce est équilibrée ») est $p = 0,5$. Comme $n \geq 30$; $np \geq 5$ et $n(1-p) \geq 5$, on peut appliquer la procédure suivante :

- On détermine $I_{100} = \left[0,5 - 1,96 \frac{\sqrt{0,5 \times 0,5}}{\sqrt{100}}; 0,5 + 1,96 \frac{\sqrt{0,5 \times 0,5}}{\sqrt{100}} \right] = [0,402; 0,598]$;
- On calcule la fréquence f d'apparition du pile : $f = 0,4$;
- Comme $f \notin I_{100}$, on rejette l'hypothèse « la pièce est équilibrée » au seuil de 5%, c'est à dire que la probabilité de rejeter à tort l'hypothèse « la pièce est équilibrée » est de 0,05. Le seuil de décision correspond à ce risque.
- Dans le cas où $f \in I_{100}$ on dit que l'on accepte l'hypothèse au seuil de 5%.

3 Intervalle de confiance

Dans une urne contenant un nombre inconnu de boules bleues et de boules rouges, on s'intéresse par exemple à la proportion p de boules bleues. Pour cela on effectue 100 tirages avec remise et on obtient 43 boules bleues soit une fréquence $f = 0,43$. Peut-on à partir de ce résultat estimer la proportion de boules bleues dans l'urne ?

Théorème:

Soit X_n une variable aléatoire suivant la loi binomiale $\mathcal{B}(n, p)$ et $F_n = \frac{X_n}{n}$ alors $P\left(F_n - \frac{1}{\sqrt{n}} \leq p \leq F_n + \frac{1}{\sqrt{n}}\right) \simeq 0,95$

Démonstration:

On sait que (vu en seconde) que $P\left(p - \frac{1}{\sqrt{n}} \leq f \leq p_n + \frac{1}{\sqrt{n}}\right) \simeq 0,95$. Or :

$$p - \frac{1}{\sqrt{n}} \leq F_n \leq p_n + \frac{1}{\sqrt{n}} \iff -F_n - \frac{1}{\sqrt{n}} \leq -p \leq -F_n + \frac{1}{\sqrt{n}} \iff F_n + \frac{1}{\sqrt{n}} \geq p \geq F_n - \frac{1}{\sqrt{n}}$$

donc

$$P\left(F_n - \frac{1}{\sqrt{n}} \leq p \leq F_n + \frac{1}{\sqrt{n}}\right) \simeq 0,95$$

Définition:

Soit f la fréquence du caractère C sur un échantillon de taille n . L'intervalle $\left[f - \frac{1}{\sqrt{n}}; f + \frac{1}{\sqrt{n}}\right]$ est un intervalle de confiance à 95% de la proportion p inconnue dans la population.

Exemple:

Avec notre problème initial, on a :

$$\left[0,43 - \frac{1}{\sqrt{100}}; 0,43 + \frac{1}{\sqrt{100}} \right] = [0,33; 0,53]$$

donc la proportion p de boules bleues dans l'urne appartient à l'intervalle $[0,33; 0,53]$ avec une probabilité de 0,95.