

# Echantillonnage

Dans ce résumé,

- $X_n$  désigne une variable aléatoire suivant une loi binomiale  $\mathcal{B}(n, p)$  où  $n \in \mathbb{N}^*$  et  $p \in ]0, 1[$ .
- $F_n = \frac{X_n}{n}$  est la variable aléatoire fréquence associée à  $X_n$ .
- $Z_n = \frac{X_n - np}{\sqrt{np(1-p)}}$  est la variable centrée et réduite associée à la variable  $X_n$ .

## I. Rappels.

### 1) Théorème de MOIVRE-LAPLACE

Pour tous réels  $a$  et  $b$  tels que  $a < b$

$$\lim_{n \rightarrow +\infty} P(a \leq Z_n \leq b) = \int_a^b \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt.$$

ou aussi

$$\lim_{n \rightarrow +\infty} P\left(p + a \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq F_n \leq p + b \frac{\sqrt{p(1-p)}}{\sqrt{n}}\right) = \int_a^b \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt.$$

### 2) Intervalle associé à une probabilité pour $\mathcal{N}(0, 1)$

**Théorème.** Soit  $X$  une variable aléatoire régie par la loi normale centrée réduite  $\mathcal{N}(0, 1)$ .

Pour tout réel  $\alpha \in ]0, 1[$ , il existe un réel strictement positif  $u_\alpha$  et un seul tel que  $P(-u_\alpha \leq X \leq u_\alpha) = 1 - \alpha$ .  
On doit connaître en particulier  $u_{0,05} = 1,96$  et  $u_{0,01} = 2,58$  à  $10^{-2}$  près par défaut.

### 3) Conséquences.

Si on combine les résultats précédents, on obtient le résultat suivant :

Pour tout entier naturel non nul  $n$ , on considère une variable aléatoire  $X_n$  qui suit une loi binomiale  $\mathcal{B}(n, p)$  puis on considère la variable aléatoire fréquence  $F_n = \frac{X_n}{n}$ . Alors :

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

et en particulier,

$$\lim_{n \rightarrow +\infty} P\left(p - 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq F_n \leq p + 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}}\right) \geq 0,95.$$

## II. Intervalle de fluctuation. Echantillonnage

Dans ce paragraphe, on étudie un caractère  $C$  d'une population et on suppose que ce caractère apparaît dans la population avec une probabilité  $p$ . On extrait un échantillon et on veut avoir une idée de la fréquence  $f$  d'apparition du caractère dans l'échantillon. La variable aléatoire qui à un échantillon de taille  $n$  associe la fréquence  $f$  d'apparition du caractère  $C$  dans l'échantillon est la variable  $F_n$ .

**Situation où on utilise un intervalle de fluctuation :**

**Quand on connaît la probabilité  $p$  (ou quand on fait une hypothèse sur la valeur de  $p$ ) et que l'on veut estimer la fréquence  $f$ .**

### A - Intervalle de fluctuation

#### 1) L'intervalle de la classe de terminale.

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

$$\lim_{n \rightarrow +\infty} P(F_n \in I_n) = \lim_{n \rightarrow +\infty} P\left(p - u_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq F_n \leq p + u_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}}\right) = 1 - \alpha.$$

En particulier, l'intervalle  $J_n = \left[ p - 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}}, p + 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}} \right]$  est un **intervalle de fluctuation asymptotique au seuil 0,95** :

$$\lim_{n \rightarrow +\infty} P(F_n \in J_n) = \lim_{n \rightarrow +\infty} P\left(p - 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq F_n \leq p + 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}}\right) \geq 0,95.$$

**Conséquence.** Pour  $n$  grand, la probabilité de l'événement «  $p - 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq F_n \leq p + 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}}$  » vaut environ 0,95. Dans la pratique, on fait cette approximation quand  $n \geq 30$ ,  $np \geq 5$ ,  $n(1-p) \geq 5$  : sous ces conditions, la fréquence  $f$  a environ 95% de chances (mais pas au moins 95% de chances) d'être dans l'intervalle  $J_n$ .

**Théorème.** Pour tout  $p \in ]0,1[$ , il existe  $n_0 \in \mathbb{N}^*$  tel que

$$\text{pour tout } n \geq n_0, P\left(p - 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq F_n \leq p + 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}}\right) \geq 0,95.$$

## 2) L'intervalle de la classe de seconde

**Théorème.** Pour tout réel  $p \in ]0,1[$  et tout entier naturel non nul  $n$ , l'intervalle  $\left[p - \frac{1}{\sqrt{n}}, p + \frac{1}{\sqrt{n}}\right]$  contient l'intervalle  $\left[p - 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq F_n \leq p + 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}}\right]$ .

**Théorème.** Pour tout  $p \in ]0,1[$ , il existe  $n_0 \in \mathbb{N}^*$  tel que pour tout  $n \geq n_0$ ,  $P\left(p - \frac{1}{\sqrt{n}} \leq F_n \leq p + \frac{1}{\sqrt{n}}\right) \geq 0,95$ .

**Théorème.** Pour tout  $n \geq 30$ ,  $np \geq 5$  et  $n(1-p) \geq 5$ ,  $P\left(p - \frac{1}{\sqrt{n}} \leq F_n \leq p + \frac{1}{\sqrt{n}}\right)$  vaut environ 0,95.

## B - Prise de décision

On cherche à savoir si la probabilité  $p$  d'apparition du caractère  $C$  dans la population est égale à un certain nombre  $p_0$  ou pas à partir d'un échantillon de taille  $n$ . On fait donc l'hypothèse que  $p = p_0$ .

- On vérifie d'abord que  $n \geq 30$ ,  $np_0 \geq 5$  et  $n(1-p_0) \geq 5$ .
- On calcule l'intervalle  $I = \left[p_0 - 1,96 \frac{\sqrt{p_0(1-p_0)}}{\sqrt{n}}, p_0 + 1,96 \frac{\sqrt{p_0(1-p_0)}}{\sqrt{n}}\right]$ .
- On détermine la fréquence  $f$  du caractère  $C$  dans l'échantillon.
- Si  $f \notin I$ , on rejette l'hypothèse  $p = p_0$  au risque de se tromper d'au plus 5%. Si  $f \in I$ , on ne peut pas rejeter l'hypothèse  $p = p_0$ .

## III. Intervalle de confiance.

Situation où on utilise un intervalle de confiance :

Quand on connaît la fréquence  $f$  et que l'on veut estimer la probabilité  $p$ .

On rappelle que pour  $n$  grand,  $P\left(F_n \in \left[p - \frac{1}{\sqrt{n}}, p + \frac{1}{\sqrt{n}}\right]\right) \geq 0,95$ . Puisque

$$p - \frac{1}{\sqrt{n}} \leq F_n \leq p + \frac{1}{\sqrt{n}} \Leftrightarrow F_n - \frac{1}{\sqrt{n}} \leq p \leq F_n + \frac{1}{\sqrt{n}} :$$

**Théorème.**

Pour tout réel  $p \in ]0,1[$ , il existe un entier  $n_0 \in \mathbb{N}^*$  tel que pour tout  $n \geq n_0$ ,  $P\left(p \in \left[F_n - \frac{1}{\sqrt{n}}, F_n + \frac{1}{\sqrt{n}}\right]\right) \geq 0,95$ .

Si on choisit explicitement un échantillon et que le caractère étudié apparaît dans cet échantillon avec une fréquence  $f$ , l'intervalle  $\left[f - \frac{1}{\sqrt{n}}, f + \frac{1}{\sqrt{n}}\right]$  est une réalisation de l'intervalle aléatoire  $\left[F_n - \frac{1}{\sqrt{n}}, F_n + \frac{1}{\sqrt{n}}\right]$ .

Quand  $n$  est grand, dans au moins 95% des choix d'échantillon, on aura  $p \in \left[f - \frac{1}{\sqrt{n}}, f + \frac{1}{\sqrt{n}}\right]$ .

On dit que l'intervalle  $\left[f - \frac{1}{\sqrt{n}}, f + \frac{1}{\sqrt{n}}\right]$  est un intervalle de confiance de  $p$  au niveau de confiance 0,95 (pour  $n$  grand). Dans la pratique, on utilise ce résultat quand  $n \geq 30$ ,  $nf \geq 5$  et  $n(1-f) \geq 5$ .