

## Échantillonnage, cours, classe de 2nde

### Définition :

On considère une population d'individus. Lorsque l'on connaît ou lorsque l'on fait une hypothèse sur la proportion  $p$  d'individus ayant une caractéristique donnée dans une population et que l'on effectue un nombre  $n$  de tirages avec remise dans cette population, la fréquence observée appartient avec une certaine probabilité à un intervalle appelé *intervalle de fluctuation* de centre  $p$  et de longueur qui diminue lorsque  $n$  augmente. On parle alors de situation *d'échantillonnage*.

### Propriété et définition :

Pour tout entier naturel  $n$ . Alors quand  $n$  « devient grand » l'intervalle

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

contient la fréquence  $f$  d'apparition du caractère étudié d'un échantillon avec une probabilité qui se rapproche de 0,95. On dit que c'est un *intervalle de fluctuation* au seuil de 95%.

### Remarque :

En pratique, on utilise cette propriété dès que les conditions  $n \geq 30$ ,  $np \geq 5$  et  $n(1 - p) \geq 5$  sont vérifiées.

### Test d'hypothèse :

On considère une population dans laquelle on suppose que la proportion d'un caractère est  $p$ . On fait l'hypothèse « La proportion dans la population est  $p$  ». On observe la fréquence  $f$  d'apparition de ce caractère sur un échantillon de taille  $n$  et on calcule l'intervalle de fluctuation  $I$  au seuil de 95%.

- Si  $f \in I$ , au risque de 5% d'erreur (ou au seuil de confiance de 95%), on accepte l'hypothèse que la proportion dans la population est  $f$ .
- Si  $f \notin I$ , au risque de 5% d'erreur on rejette l'hypothèse que la proportion dans la population est  $p$ .

### Exemple :

Un fournisseur d'accès à l'internet affirme que, sur sa hotline, seuls 20% des clients attendent plus de 5 minutes pour obtenir un interlocuteur. Une association de consommateurs interroge au hasard 200 personnes ayant eu à s'adresser à cette hotline. Parmi ces personnes, 53 ont dû attendre plus de 5 minutes. Peut-on mettre en doute l'affirmation du fournisseur d'accès ?

L'hypothèse à tester est « 20% des clients attendent plus de 5 minutes ».

$$\frac{53}{200} = 0,265 \text{ et } I = \left[ 0,2 - \frac{1}{\sqrt{200}}; 0,2 + \frac{1}{\sqrt{200}} \right] = [0,129; 0,271].$$

Or  $0,265 \notin I$  donc au seuil de confiance de 95%, on ne peut pas mettre en doute l'affirmation du fournisseur d'accès.

# 1 Estimation

**Propriété et définition :**

Soit  $X_n$  une variable aléatoire suivant la loi binomiale  $\mathcal{B}(n; p)$  et  $F_n = \frac{X_n}{n}$  où  $p$  est la proportion inconnue d'apparition d'un caractère.

- Alors, pour  $n$  assez grand,  $P(p \in [F_n - \frac{1}{\sqrt{n}}; F_n + \frac{1}{\sqrt{n}}]) \geq 0,95$ .
- Si on appelle  $f$  la fréquence d'apparition du caractère sur un échantillon de taille  $n$ , Alors l'intervalle  $[f - \frac{1}{\sqrt{n}}; f + \frac{1}{\sqrt{n}}]$  est appelé *intervalle de confiance de la proportion  $p$  inconnue au niveau de confiance 0,95*.

**Remarque :**

Un intervalle de confiance au niveau de 95% a une amplitude de  $\frac{2}{\sqrt{n}}$ . L'amplitude diminue lorsque la taille  $n$  de l'échantillon augmente.

**Exemple :**

Un candidat à une élection municipale fait effectuer un sondage. Sur 100 personnes de la ville interrogées, 63 déclarent vouloir voter pour lui.

$$I = [0,63 - \frac{1}{\sqrt{100}}; 0,63 + \frac{1}{\sqrt{100}}] = [0,53; 0,73]$$

On peut donc estimer que la proportion de personnes dans la ville voulant voter pour lui est comprise dans l'intervalle  $I=[0,53;073]$ .