

# Intervalle de fluctuations - Intervalle de confiance

## I Distinction entre échantillonnage et estimation



### 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.
- Lorsque l'on ne connaît pas la proportion d'individus ayant une caractéristique donnée, en procédant à un nombre  $n$  de tirages avec remise on peut estimer à l'aide de la fréquence  $f$  obtenue la proportion  $p$  d'individus ayant cette caractéristique.  
Cette estimation se fait à l'aide d'un intervalle de confiance dont l'amplitude diminue lorsque le nombre  $n$  de tirages augmente.

## II Échantillonnage



### Propriété et définition

Pour tout entier naturel  $n$ , soit  $X_n$  une variable aléatoire suivant une loi binomiale  $\mathcal{B}(n; p)$ . Alors quand  $n$  devient grand, l'intervalle  $I_n = \left[ p - \frac{1}{\sqrt{n}} ; p + \frac{1}{\sqrt{n}} \right]$  contient la fréquence  $X_n$  avec une probabilité qui se rapproche de 0,95. On dit que c'est un intervalle de fluctuation asymptotique 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 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 ?

On a  $p : 0,2 ; n = 200$ .

Les conditions sont vérifiées. L'intervalle de fluctuation est  $I = \left[ 0,2 - \frac{1}{\sqrt{200}} ; 0,2 + \frac{1}{\sqrt{200}} \right] \approx [0,129 ; 0,271]$ .

L'hypothèse à tester est « 20 % des clients attendent plus de 5 minutes ». La fréquence observée est  $f = \frac{53}{200} \approx 0,265$ .

$f \in [0,129; 0,271]$ .

Donc au seuil de confiance de 95 %, on ne peut pas mettre en doute l'affirmation du fournisseur d'accès.

### III Estimation



#### Propriété et définition

Soit  $p$  la proportion inconnue d'apparition d'un caractère. On appelle  $f$  la fréquence d'apparition du caractère sur un échantillon de taille  $n$ . Alors, l'intervalle  $\left[ f - \frac{1}{\sqrt{n}} ; f + \frac{1}{\sqrt{n}} \right]$  contient pour  $n$  assez grand la proportion  $p$  avec une probabilité supérieure ou égale à 0,95. 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.

**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 :** Lors d'un scrutin électoral, on souhaite connaître la proportion  $p$  de français votant pour le candidat « A ».

L'institut SOFOS mène une enquête auprès de 1 000 personnes tirées au hasard et avec remise (c'est-à-dire qu'une même personne peut éventuellement être choisie plusieurs fois). Le résultat indique qu'une proportion  $f = 49\%$  d'entre elles voteront pour le candidat « A ».

1. Quelle est la loi suivie par le nombre de personnes votant pour « A » dans une enquête avec remise effectuée auprès de 1 000 personnes ?
2. Étant donné le résultat de l'enquête SOFOS, donner un intervalle de confiance à 95 % pour l'estimation de  $p$ .
3. Peut-on affirmer d'après l'enquête que le candidat « A » n'aura pas la majorité des votes, c'est-à-dire que  $p < 0,5$  ?

#### Solution

1. À chaque étape de l'enquête, il y a une probabilité  $p$  de tirer une personne votant pour « A », car on procède à des tirages avec remise. De plus, les 1 000 tirages sont effectués de façon indépendante. L'enquête est donc un schéma de Bernoulli dont chaque succès correspond à tirer une personne votant pour « A ». Le nombre de personnes votant pour « A » dans l'enquête suit donc une loi binomiale  $\mathcal{B}(n; p)$  où  $p$  est inconnu.
2. Notons  $F$  la proportion de personnes votant pour « A » parmi 1 000.  
D'après le cours, si  $n \geq 30$ ,  $np > 5$ ,  $n(1-p) > 5$ , un intervalle de confiance au niveau 95 % pour  $p$  est  $\left[ F - \frac{1}{\sqrt{1000}} ; F + \frac{1}{\sqrt{1000}} \right]$ .  
Ici,  $n = 1000 > 30$ ,  $np \geq 5 \Leftrightarrow p \geq 0,005$  et  $n(1-p) \geq 5 \Leftrightarrow p \leq 0,995$ .  
On ne connaît pas  $p$ , mais au vu de l'enquête,  $f = 0,49$ , donc on peut raisonnablement penser que  $p$  les conditions sont vérifiées.  
L'intervalle de confiance est  $\left[ 0,49 - \frac{1}{\sqrt{1000}} ; 0,49 + \frac{1}{\sqrt{1000}} \right] = [0,458 ; 0,522]$ .
3. L'intervalle de confiance précédent montre qu'il est tout à fait possible que  $p \geq 0,5$ .  
Donc il n'est pas raisonnable d'affirmer suite à l'enquête que le candidat « A » n'obtiendra pas majorité des votes.