

## ESTIMATION EN TERMINALE ES ET L

### I - INTERVALLE DE FLUCTUATION

Pour étudier un caractère présent dans une population, on prélève de façon aléatoire un échantillon dans cette population.

On suppose connues :

- la proportion  $p$  du caractère **dans la population**
- la taille  $n$  de l'échantillon

On cherche à évaluer :

- la fréquence  $f$  du caractère **dans l'échantillon**

#### EXEMPLE

On sait que 48% des élèves d'un lycée sont des garçons (et donc 52% sont des filles...).

Si l'on sélectionne au hasard 100 élèves dans l'établissement, on devrait obtenir *environ* 52 filles et 48 garçons mais il n'est pas du tout certain que l'on obtienne **exactement** ces chiffres.

Par contre, on pourra rechercher un intervalle dans lequel se situera "*probablement*" la proportion de garçons dans cet échantillon.

Si  $n$  est élevé, on peut assimiler la sélection de l'échantillon à un tirage avec remise. Le nombre d'individus présentant le caractère étudié suit alors une loi binomiale  $\mathcal{B}(n, p)$ . Pour  $n$  élevé, on peut approximer cette loi binomiale par une loi normale. On obtient alors le résultat suivant :

#### DÉFINITION ET PROPRIÉTÉ

On appelle **intervalle de fluctuation asymptotique au seuil de 95%** l'intervalle :

$$I = \left[ p - 1,96 \times \frac{\sqrt{p(1-p)}}{\sqrt{n}}; p + 1,96 \times \frac{\sqrt{p(1-p)}}{\sqrt{n}} \right]$$

Cela s'interprète de la façon suivante :

Pour  $n$  élevé, la probabilité que la fréquence  $f$  du caractère dans l'échantillon appartienne à  $I$  est 0,95.

#### EXEMPLE

Si l'on reprend l'exemple précédent, on a  $n = 100$  et  $p = \frac{48}{100}$ .

On trouve  $I = [0,38; 0,58]$ .

La proportion de garçons dans l'échantillon devrait être comprise entre 38% et 58% (avec une probabilité de 0,95)

#### REMARQUES

- On considèrera que  $n$  est suffisamment élevé pour utiliser cet intervalle de fluctuation si  $n \geq 30$ ,  $np \geq 5$  et  $n(1-p) \geq 5$

- L' intervalle de fluctuation peut être utilisé pour valider ou rejeter une hypothèse. On procède de la façon suivante :
  - On suppose que la proportion du caractère étudié est  $p$ .
  - On prélève un échantillon de taille  $n$ .
  - On regarde si la fréquence  $f$  du caractère dans l'échantillon appartient à  $I$ .
  - Si oui, l'hypothèse est validée; si non, elle est rejetée.  
Le risque de rejeter l'hypothèse à tort est alors inférieur à 5%.
- Pour des valeurs moyennes de  $p$  (par exemple  $0,2 \leq p \leq 0,8$ ),  $1,96 \times \sqrt{p(1-p)}$  est proche de 1 (et légèrement inférieur). Si l'on arrondit  $1,96 \times \sqrt{p(1-p)}$  à 1, on obtient :

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

qui est l'intervalle vu en Seconde.

## II - INTERVALLE DE CONFIANCE

Dans cette partie (contrairement à la première partie), on suppose que l'**on connaît la fréquence  $f$  du caractère dans l'échantillon** mais que l' **on ne connaît pas la proportion  $p$  du caractère dans la population**.

On cherche alors à évaluer  $p$ .

### DÉFINITION ET PROPRIÉTÉ

On appelle **intervalle de confiance avec un niveau de confiance de 95%** l'intervalle :

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

Pour  $n$  élevé, la proportion  $p$  du caractère dans la population appartiendra à  $I$  dans 95% des cas.

### EXEMPLE

On recherche le pourcentage de truites femelles dans un élevage de truites.

Pour cela, on a prélevé un échantillon de 50 truites et on a comptabilisé 28 femelles dans cet échantillon.

Le pourcentage de truites femelles dans l'ensemble de l'élevage appartient donc à l'intervalle :

$$I = \left[ \frac{28}{50} - \frac{1}{\sqrt{50}}; \frac{28}{50} + \frac{1}{\sqrt{50}} \right] \approx [0,42; 0,70]$$

avec un risque d'erreur inférieur à 5%.

### REMARQUE

La longueur de l'intervalle  $I$  est  $\frac{2}{\sqrt{n}}$ .

Si l'on souhaite obtenir un intervalle d'amplitude maximale  $a$ , il faut choisir  $n$  tel que  $\frac{2}{\sqrt{n}} \leq a$  c'est à dire  $n \geq \frac{4}{a^2}$ .