

ESTIMATION

I. Introduction :

1°) Vocabulaire :

Définitions :

Lorsqu'on étudie une partie de la population, on dit qu'on étudie un **échantillon**.

Le nombre d'individus formant l'échantillon est appelé **taille de l'échantillon**. Nous le noterons n .

2°) Introduction :

Introduction :

Dans ce chapitre, on est dans le cas où on ne connaît pas les caractéristiques (proportion et/ou moyenne) d'une population et on cherche à en donner une estimation à partir de l'étude d'échantillons.

II. Estimation ponctuelle :

Propriété :

Connaissant la moyenne \bar{x} et l'écart-type σ_s d'un échantillon de taille n , il s'agit d'estimer la moyenne m et l'écart-type σ de la population totale. L'estimation ponctuelle consiste à confondre la moyenne de l'échantillon avec la moyenne de la population totale. On dira que \bar{x} est une estimation ponctuelle de la moyenne m .

En choisissant la variance σ_s^2 d'un échantillon prélevé au hasard comme estimation ponctuelle de la variance inconnue σ^2 d'une population, on sous-estime la variance de la population.

On choisit donc:

- la moyenne \bar{x} comme estimation ponctuelle de la moyenne m ;
- l'écart type $\sqrt{\frac{n}{n-1}} \sigma_s$ comme estimation ponctuelle de l'écart-type inconnu σ de cette population.

Remarque :

Le nombre $\sqrt{\frac{n}{n-1}} \sigma_s$ est fourni directement par la calculatrice : Sx ou $\sigma n - 1$.

III. Estimation par intervalle de confiance :

1°) Estimation d'une proportion, dans le cas d'une loi binomiale approximable par une loi normale :

Propriété :

Nommons p la proportion dans la population (donc inconnue ici) et f la proportion obtenue dans l'échantillon.

Pour tout réel α dans $]0 ; 1[$, l'intervalle $I = \left[f - u_\alpha \frac{\sqrt{f(1-f)}}{\sqrt{n}} ; f + u_\alpha \frac{\sqrt{f(1-f)}}{\sqrt{n}} \right]$ où u_α désigne le nombre réel tel que $P(-u_\alpha \leq Z \leq u_\alpha) = 1 - \alpha$ lorsque Z suit la loi normale $\mathcal{N}(0 ; 1)$ est un intervalle de confiance de la proportion p au seuil de $1 - \alpha$.

Remarques :

- $1 - \alpha$ est appelé le coefficient de confiance ;
- Si $\alpha = 0,05$, c'est-à-dire 5 %, cela signifie que dans 95 % des cas la proportion p cherchée est dans I ;
- Cet intervalle est centré en f .

Exemple, Méthode d'utilisation :

On voudrait estimer la proportion de téléspectateurs ayant regardé hier soir une émission sur un célèbre mathématicien, avec un coefficient de confiance de 97 %. Pour ce faire, on interroge 900 téléspectateurs tirés au hasard. Sur ces 900 personnes, 240 déclarent avoir vu l'émission.

On obtient donc $f \approx 0,267$.

On cherche ensuite $u_{0,03}$. $P(-u_{0,03} \leq Z \leq u_{0,03}) = 0,97$, donc $P(Z \leq u_{0,03}) = 0,985$. En tapant `FracNormal(0.985,0,1)` à la calculatrice, on obtient $u_{0,03} \approx 2,17$.

$$\text{Ce qui donne } I = \left[0,267 - 2,17 \frac{\sqrt{0,267(1-0,267)}}{\sqrt{900}}; 0,267 + 2,17 \frac{\sqrt{0,267(1-0,267)}}{\sqrt{900}} \right] \approx [0,235 ; 0,299].$$

La proportion de téléspectateurs ayant regardé cette émission est donc entre 23,5 % et 29,9 % au seuil de confiance de 97 %.

Remarque :

Deux seuils de confiance fréquemment utilisés sont ceux de 95 % et 99 %, il peut donc être intéressant de connaître par cœur $u_{0,05} \approx 1,96$ et $u_{0,01} \approx 2,58$.

2°) Estimation d'une moyenne, dans le cas d'une loi normale quand l'écart type de la population est connu :

Propriété :

Nommons m la moyenne dans la population (donc inconnue ici) et \bar{x} la moyenne obtenue dans l'échantillon.

Pour tout réel α dans $]0 ; 1[$, l'intervalle $I = \left[\bar{x} - u_\alpha \frac{\sigma}{\sqrt{n}}; \bar{x} + u_\alpha \frac{\sigma}{\sqrt{n}} \right]$ où u_α désigne le nombre réel tel que $P(-u_\alpha \leq Z \leq u_\alpha) = 1 - \alpha$ lorsque Z suit la loi normale $\mathcal{N}(0 ; 1)$ est un intervalle de confiance de la moyenne m au seuil de $1 - \alpha$.

3°) Précision de l'intervalle de confiance :

Exemple :

Reprenons l'exemple des téléspectateurs précédent, mais cette fois on se demande combien de personnes on devrait interroger pour que l'erreur de notre estimation soit de moins de 1 %, c'est-à-dire pour que l'amplitude de l'intervalle de confiance soit inférieure à 0,01. Rappelons que l'intervalle de confiance est

$$I = \left[0,267 - 2,17 \frac{\sqrt{0,267(1-0,267)}}{\sqrt{n}}; 0,267 + 2,17 \frac{\sqrt{0,267(1-0,267)}}{\sqrt{n}} \right], \text{ car } n \text{ est inconnue cette fois. Comme } 2,17 \sqrt{0,267(1-0,267)} \approx 0,96, \text{ on obtient } I = \left[0,267 - \frac{0,96}{\sqrt{n}}; 0,267 + \frac{0,96}{\sqrt{n}} \right].$$

Son amplitude est de $\frac{2 \times 0,96}{\sqrt{n}} = \frac{1,92}{\sqrt{n}}$, on veut donc $\frac{1,92}{\sqrt{n}} < 0,01$, soit $\frac{1,92}{0,01} < \sqrt{n} \Leftrightarrow 192 < \sqrt{n}$, et donc, comme $n > 0$, $n > 192^2$ soit $n > 36\ 864$.

Il faudrait donc interroger au moins 36 864 téléspectateurs pour que l'erreur de l'estimation soit inférieure à 1 %.