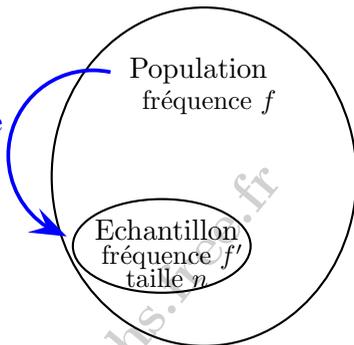


Fluctuations

Dans une population donnée, on connaît la fréquence f d'un caractère.

Echantillonnage
(déduction)

On répète n fois, de façon indépendante et aléatoire, le choix d'un individu dans cette population de façon à constituer un échantillon de taille n . La fréquence f' du caractère dans l'échantillon peut varier d'un échantillon à l'autre (sa constitution est aléatoire).



Propriété L'intervalle de fluctuation au seuil de 95% est environ :

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

Cet intervalle signifie que dans 95% des cas (ou avec une probabilité de 0,95) la fréquence observée dans un échantillon prélevé au hasard dans la population sera dans l'intervalle I .

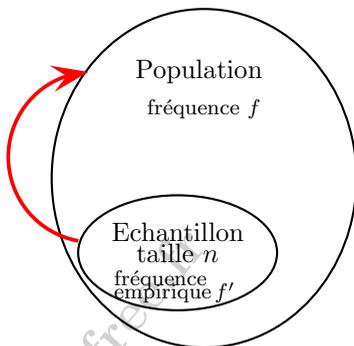
Si pour un échantillon donné la fréquence observée n'appartient pas à I , alors on peut remettre en cause, avec un risque d'erreur de 5% les hypothèses mises en jeu : l'échantillon est constitué aléatoirement, la fréquence dans la population complète est f, \dots

Estimation

On connaît la fréquence f' d'un caractère d'un échantillon aléatoire de la population.

Inférence
(induction)

A partir de la connaissance de cette fréquence empirique f' , on souhaite estimer la fréquence f du caractère dans la population complète.



Propriété L'intervalle $I_n = \left[f' - \frac{1}{\sqrt{n}} ; f' + \frac{1}{\sqrt{n}} \right]$.

contient la fréquence f du caractère dans la population avec une probabilité supérieure ou égale à 0,95.

I_n est l'intervalle au niveau de confiance de 95 %.

Dimensionnement des échantillons (ou sondages) La largeur de l'intervalle de confiance, ou précision de l'estimation est $\frac{2}{\sqrt{n}}$.

Ainsi, pour obtenir une estimation (toujours avec un niveau de confiance de 95%) de la fréquence f avec une précision ε donnée, on doit donc avoir $\frac{2}{\sqrt{n}} \leq \varepsilon \iff n \geq \left(\frac{2}{\varepsilon}\right)^2$