

## Echantillonnage et estimation


La théorie de l'échantillonnage consiste, connaissant des propriétés d'une population, à déterminer des propriétés d'échantillons prélevés dans la population.

En réalité, on est plus souvent confronté au problème inverse, celui de l'estimation: déduire des informations sur la population totale à partir de renseignements donnés par des échantillons.

Le tirage des éléments d'un échantillon aléatoire peut être exhaustif ( sans remise ); dans ce cas la composition de l'urne est modifiée à chaque tirage: les tirages ne sont donc pas indépendants.

Sinon le tirage est non exhaustif (avec remise ); dans ce cas la composition de l'urne n'est pas modifiée à chaque tirage: les tirages sont donc indépendants.

Dans la plupart des cas où la population a un grand effectif  $N$  dont on tire un petit nombre d'éléments  $n$  on assimile un tirage sans remise à un tirage avec remise.



Intervalle de fluctuation asymptotique d'une fréquence, au seuil de 95%, avec une loi normale

Considérons une population d'effectif  $N$  dont un pourcentage  $p$  d'éléments possède un certain caractère. On prélève au hasard des échantillons de taille  $n$  et on mesure pour chacun la fréquence  $f$  des éléments possédant ce caractère.

$E_1$  : effectif  $n$ , fréquence  $f_1$       ...       $E_k$  : effectif  $n$ , fréquence  $f_k$

Soit  $F$  la variable aléatoire qui à tout échantillon de taille  $n$  associe la fréquence du caractère observé.

Lorsque  $n \geq 30$ ,  $np \geq 5$  et  $n(1-p) \geq 5$  : 
$$P\left(F \in \left[ p - 1,96\sqrt{\frac{p(1-p)}{n}} ; p + 1,96\sqrt{\frac{p(1-p)}{n}} \right] \right) = 0,95$$


L'intervalle  $\left[ p - 1,96\sqrt{\frac{p(1-p)}{n}} ; p + 1,96\sqrt{\frac{p(1-p)}{n}} \right]$  est appelé intervalle de fluctuation asymptotique de

$F$  au seuil de 95%.

Autrement dit, lorsqu'on prélève un échantillon de taille  $n$  en respectant les conditions données il y a 95% de chances que la fréquence dans cet échantillon soit dans l'intervalle :

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

Parmi les échantillons de taille  $n$ , 95% ont une fréquence comprise dans l'intervalle donné



Intervalle de fluctuation d'une fréquence, au seuil de 95%, avec une loi binomiale

Si les conditions ne sont pas respectées, l'intervalle de fluctuation asymptotique à environ 95% d'une fréquence correspondant à la réalisation sur un échantillon aléatoire de taille  $n$ , d'une variable aléatoire  $X$  de loi binomiale, est l'intervalle  $\left[ \frac{a}{n}; \frac{b}{n} \right]$  défini par :

$a$  est le plus petit entier naturel tel que  $p(X \leq a) > 0,025$

$b$  est le plus petit entier naturel tel que  $p(X \leq b) \geq 0,975$

p.300 : 54, 57, 58	p.299 : 52, 55
--------------------	----------------

Prise de décision

Soit  $p$  la proportion supposée du caractère dans la population et  $f$  la fréquence connue du caractère dans l'échantillon de taille  $n$ .


Si  $f$  appartient pas à l'intervalle de fluctuation asymptotique  $\left[ p - 1,96\sqrt{\frac{p(1-p)}{n}}; p + 1,96\sqrt{\frac{p(1-p)}{n}} \right]$ , on

ne rejette pas, au seuil de 5%, l'hypothèse selon laquelle la proportion dans la population est  $p$ . Dans le cas contraire, on la rejette.

On peut également utiliser l'intervalle de fluctuation issu de la loi binomiale :  $\left[ \frac{a}{n}; \frac{b}{n} \right]$  défini par :

$a$  est le plus petit entier naturel tel que  $p(X \leq a) > 0,025$

$b$  est le plus petit entier naturel tel que  $p(X \leq b) \geq 0,975$



p.303 : 60, 62	p.271 : ER5, p.302 : 59, 61
----------------	-----------------------------

Intervalle de confiance d'une proportion .


A l'aide d'un échantillon, nous allons définir, avec un coefficient de confiance choisi à l'avance, un intervalle de confiance de la proportion  $p$  des éléments de la population possédant un certain caractère.

Lorsque  $n \geq 30$ ,  $np \geq 5$  et  $n(1-p) \geq 5$  :  $P\left(p \in \left[ f - 1,96\sqrt{\frac{f(1-f)}{n}}; f + 1,96\sqrt{\frac{f(1-f)}{n}} \right] \right) = 0,95$

L'intervalle  $\left[ f - 1,96\sqrt{\frac{f(1-f)}{n}}; f + 1,96\sqrt{\frac{f(1-f)}{n}} \right]$  est appelé intervalle de confiance de  $p$  au niveau de confiance de 95%.

Autrement dit, lorsqu'on prélève un échantillon de taille  $n$  en respectant les conditions données il y a 95% de chances que la proportion dans la population soit dans l'intervalle :

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



### Comparaison de deux populations.


Considérons un caractère observé sur deux populations différentes  $P_1$  et  $P_2$ . Les proportions ( inconnues) dans ces deux populations sont appelées  $p_1$  et  $p_2$ .

Considérons un échantillon de fréquence  $f_1$  provenant de  $P_1$  et un échantillon de fréquence  $f_2$  provenant de  $P_2$ .

Pour savoir si les proportions  $p_1$  et  $p_2$  sont significativement différentes au seuil de 95%, on détermine les intervalles de confiance de chacun.

Si les deux intervalles à 95% sont disjoints, on considère ( au risque de 5%) que les proportions  $p_1$  et  $p_2$  sont différentes.

Dans le cas contraire, on considère ( au risque de 5%) que les proportions  $p_1$  et  $p_2$  sont égales.



p.305 : 69, 70

p.275 : ER6, p.305 : 68

### Devoir Maison

p.306 : 71