



ESTIMATION : INTERVALLE(S) DE CONFIANCE

I. De la fluctuation d'échantillonnage à un intervalle aléatoire	2
II. Un intervalle de confiance au niveau 0,95	2
III. Complément : un autre intervalle de confiance	4

Présidentielle 2017 : évolution des sondages

2017

Compilation des derniers sondages, marge d'erreur de chaque enquête incluse



I. De la fluctuation d'échantillonnage à un intervalle aléatoire

PROPRIÉTÉ . Soit $X_n \sim \mathcal{B}(n; p)$. On note $F_n = \frac{X_n}{n}$.

Lorsque n est assez grand, l'intervalle $\left[F_n - \frac{1}{\sqrt{n}}; F_n + \frac{1}{\sqrt{n}} \right]$ contient la proportion p avec une probabilité environ égale à 0,95.

Démonstration : On a dès la Seconde que : $p \left(F_n \in \left[p - \frac{1}{\sqrt{n}}; p + \frac{1}{\sqrt{n}} \right] \right) \approx 0,95$.

$$\text{Or : } F_n \in \left[p - \frac{1}{\sqrt{n}}; p + \frac{1}{\sqrt{n}} \right] \Leftrightarrow$$

Donc la probabilité pour que l'intervalle aléatoire $\left[F_n - \frac{1}{\sqrt{n}}; F_n + \frac{1}{\sqrt{n}} \right]$ contienne p est environ égale à 0,95.

II. Un intervalle de confiance au niveau 0,95

On souhaite connaître, dans une population, la valeur d'une proportion p (proportion des gauchers en France, intentions de vote pour une élection, ...).

Pour des raisons matérielles, financières ou autres¹, on ne peut pas toujours réunir les données concernant la population tout entière.

On va donc *estimer la proportion p que l'on cherche à partir de la fréquence f observée dans un échantillon*.

Rappel : on sait que cette fréquence observée va varier d'un échantillon à l'autre, c'est la fluctuation d'échantillonnage autour de p .

Grâce aux propriétés précédentes, on a vu que :

Si n est assez grand, la probabilité qu'un échantillon de taille n de cette population ait une fréquence f qui appartienne à l'intervalle de fluctuation $\left[p - \frac{1}{\sqrt{n}}; p + \frac{1}{\sqrt{n}} \right]$ est strictement supérieure à 95 %.

C'est la fluctuation d'échantillonnage.

Soit p une proportion inconnue dans une population.

Pour un échantillon de taille n de cette population, on calcule la fréquence f .

Alors la probabilité que l'intervalle $\left[f - \frac{1}{\sqrt{n}}; f + \frac{1}{\sqrt{n}} \right]$ contienne p est strictement supérieure à 95 %.

¹ par exemple, on ne peut pas tester le bon fonctionnement de toutes les allumettes d'une production car dans ce cas tester une allumette amène à la détruire...

Autrement dit, parmi tous les échantillons de taille n qu'on peut obtenir, au moins 95 % d'entre eux sont tels que l'intervalle $\left[f - \frac{1}{\sqrt{n}}; f + \frac{1}{\sqrt{n}} \right]$ contient la proportion p .

On dit donc que $\left[f - \frac{1}{\sqrt{n}}; f + \frac{1}{\sqrt{n}} \right]$ est **un intervalle de confiance** de la proportion inconnue p à un niveau de confiance de 0,95.

DÉFINITION.

Soit f la fréquence observée d'un caractère dans un échantillon de taille n extrait d'une population dans laquelle la proportion de ce caractère est p (inconnue).


L'intervalle $\left[f - \frac{1}{\sqrt{n}}; f + \frac{1}{\sqrt{n}} \right]$ est **un intervalle de confiance de la proportion p au niveau de confiance de 0,95.**

On admet que l'on « peut » utiliser cet intervalle lorsque :

$$n \geq 30 \quad ; \quad n f \geq 5 \quad ; \quad n(1-f) \geq 5 .$$

(les conditions sur p de l'int. de fluct. sont appliquées à f)

ATTENTION : à chaque tirage d'un échantillon, on obtient un intervalle de confiance différent. Et un intervalle de confiance peut ne pas contenir p . Un exemple :



Il s'agit d'une suite de 100 intervalles de confiance au niveau de confiance 0,95, dont chacun a été calculé sur un échantillon de taille 1000 simulé à partir de ce que fut le score de Barack Obama à l'élection présidentielle aux U.S.A. en 2012, à savoir 0,51 : dans cette simulation on observe 96 intervalles auxquels appartient la valeur 0,51 (dont 2 auxquels elle n'appartient que « de justesse »).

Source : <http://images.math.cnrs.fr/Intervalle-de-confiance-le-debat.html>

1. Il est incorrect de conclure la détermination d'un intervalle de confiance par la phrase « p a une probabilité de 0,95 d'être entre $f - \frac{1}{\sqrt{n}}$ et $f + \frac{1}{\sqrt{n}}$ » car il n'y a plus d'aléatoire à ce stade : p est inconnue mais ne varie pas !

C'est pourquoi, plutôt que de parler de « probabilité », on a choisi le mot « confiance » :

« L'intervalle $\left[f - \frac{1}{\sqrt{n}}; f + \frac{1}{\sqrt{n}} \right]$ est un intervalle de confiance
de la proportion inconnue p au niveau de confiance 0,95 ».

2. La précision de l'estimation est donnée par l'amplitude de l'intervalle $\left[f - \frac{1}{\sqrt{n}}; f + \frac{1}{\sqrt{n}} \right]$, qui est $\frac{2}{\sqrt{n}}$.

Cette valeur dépend donc uniquement de n , pas de la taille de la population totale².

Si on veut une précision de a , on cherche à partir de quel n on a : $\frac{2}{\sqrt{n}} \leq a$.

Or : $\frac{2}{\sqrt{n}} \leq a \Leftrightarrow n \geq \frac{4}{a^2}$.

Voici quelques exemples :

a	0,1	0,09	0,08	0,07	0,06	0,05	0,04	0,03	0,02	0,01
n					1112					

Donc, avec un niveau de confiance de 0,95, pour obtenir un intervalle de confiance d'amplitude 0,06, il faut un échantillon de taille 1112 au moins.

III. Complément : un autre intervalle de confiance

Dans les démonstrations, nous avons utilisé le résultat suivant, facile à démontrer :

$$F_n \in \left[p - \frac{1}{\sqrt{n}}; p + \frac{1}{\sqrt{n}} \right] \Leftrightarrow p \in \left[F_n - \frac{1}{\sqrt{n}}; F_n + \frac{1}{\sqrt{n}} \right].$$

Mais si on utilise l'intervalle de fluctuation de Terminale, c'est beaucoup plus difficile d'encadrer p ...

En effet, écrire $F_n \in \left[p - 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}}; p + 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}} \right]$ ne permet pas d'encadrer p .

D'après le programme scolaire, « il est important de noter que, dans d'autres champs disciplinaires, on utilise l'intervalle $\left[f - 1,96 \frac{\sqrt{f(1-f)}}{\sqrt{n}}; f + 1,96 \frac{\sqrt{f(1-f)}}{\sqrt{n}} \right]$, qu'il n'est pas possible de justifier en Terminale ».

2 Ce qui peut étonner... Mais comme l'a dit Jean-Louis Boursin dans « les structures du hasard » : pour goûter un plat, il suffit d'en goûter une petite quantité ; cette quantité ne dépend pas de la taille du récipient (mais il faut néanmoins avoir bien mélangé) !