



# 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 .....	3
III. Complément : un autre intervalle de confiance .....	5

## 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.

Ce « lorsque  $n$  est assez grand » est peu précis. On peut dire, plus précisément :

ROC

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

Il existe un entier  $n_0$  tel que, pour tout entier naturel  $n \geq n_0$  :

$$p\left(F_n \in \left[p - \frac{1}{\sqrt{n}}; p + \frac{1}{\sqrt{n}}\right]\right) > 0,95.$$

**Démonstration** :

$$\text{On pose } Z_n = \frac{X_n - np}{\sqrt{np(1-p)}}.$$

On admet qu'il existe un entier  $n_0$  tel que, pour tout entier naturel  $n \geq n_0$  :

$$p(-2 \leq Z_n \leq 2) > 0,95 \text{ où } T \sim N(0; 1).$$

1. Démontrer que, pour tout entier naturel  $n \geq n_0$  :

$$p\left(p - 2 \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq \frac{X_n}{n} \leq p + 2 \frac{\sqrt{p(1-p)}}{\sqrt{n}}\right) > 0,95.$$

2. On définit sur  $[0; 1]$  la fonction  $f$  par  $f(p) = p(1-p)$ .

a) Étudier la fonction  $f$  et dresser son tableau de variations sur  $[0; 1]$ .

b) En déduire que  $0 \leq \sqrt{p(1-p)} \leq \frac{1}{2}$ .

c) En déduire que, pour tout entier naturel  $n \geq n_0$  :  $p\left(p - \frac{1}{\sqrt{n}} \leq \frac{X_n}{n} \leq p + \frac{1}{\sqrt{n}}\right) > 0,95$ .

Et en remarquant que  $F_n \in \left[ p - \frac{1}{\sqrt{n}}; p + \frac{1}{\sqrt{n}} \right] \Leftrightarrow p \in \left[ F_n - \frac{1}{\sqrt{n}}; F_n + \frac{1}{\sqrt{n}} \right]$ , on en déduit :

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

Il existe un entier  $n_0$  tel que, pour tout entier naturel  $n \geq n_0$ , l'intervalle  $\left[ F_n - \frac{1}{\sqrt{n}}; F_n + \frac{1}{\sqrt{n}} \right]$  contient la proportion  $p$  avec une probabilité supérieure ou égale à 0,95.

Remarque : cet entier  $n_0$  dépend de  $p$ , et peut varier considérablement.

A l'aide d'algorithmes, on peut obtenir le tableau suivant :

$p$	0,35	0,36	0,37	0,38	0,39	0,4	0,41	0,42	0,43	0,44	0,45	0,46	0,47	0,48	0,49	0,5
$n_0$	31	30	36	64	56	81	90	120	143	209	271	288	304	399	399	529

## 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 autres<sup>1</sup>, 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 %.

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.

<sup>1</sup> 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...

#### 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>

### A SAVOIR

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 totale<sup>2</sup>.

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

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

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 ».

<sup>2</sup> 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) !