

Niveau :


Terminale S

Titre Cours :

Chapitre 11
Echantillonnage et estimation

Année :

2015-2016

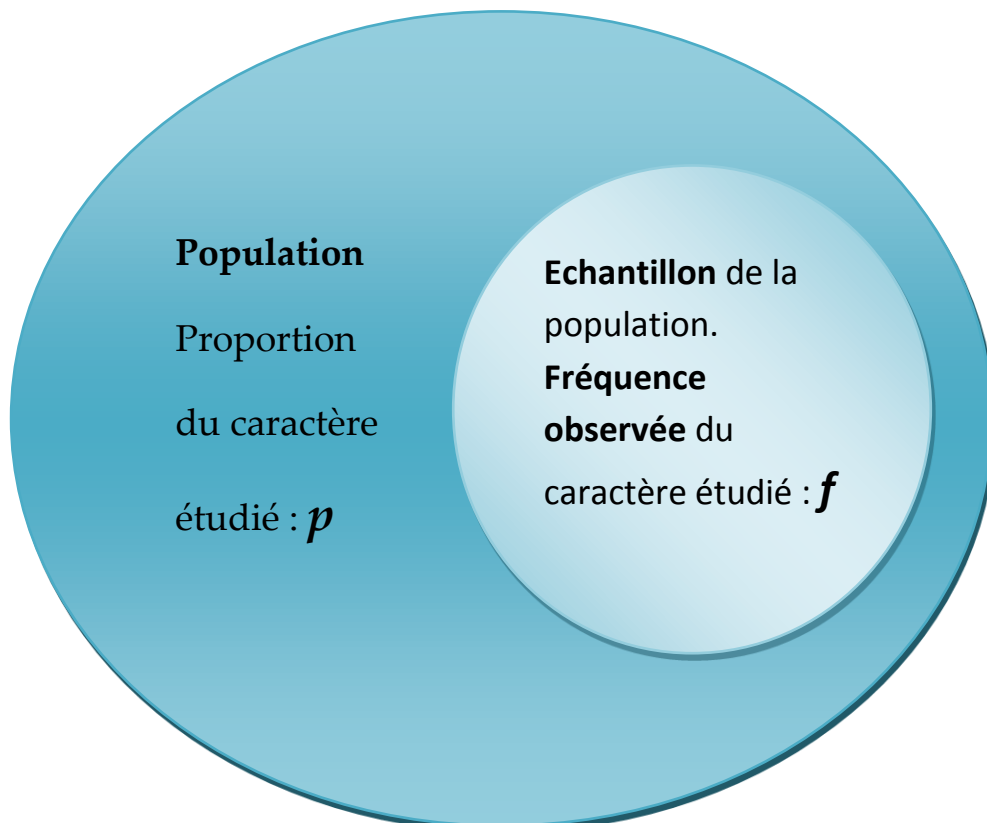


Abraham de Moivre (1667-1754)
Mathématicien Français

Citation du moment :

«Un probabiliste est une personne qui peut avoir la tête dans un four et les pieds pris dans la glace tout en disant qu'en moyenne il se sent bien» (Anonyme : Livre de Patrick Bogaert)

I. Situation



On souhaite étudier un caractère dans une population (Ex : Ceux qui ont voté pour un candidat,).

Deux possibilités s'offrent à nous :

- **Echantillonnage** : Soit on connaît la **proportion p** d'individus ayant ce caractère dans l'ensemble de la population et on souhaite savoir dans quel intervalle va fluctuer (**intervalle de fluctuation**) la fréquence de ce caractère dans un échantillon obtenu. Si la fréquence f de l'échantillon est dans l'intervalle de fluctuation, alors on dira que l'échantillon est représentatif de la population.
- **Estimation** : Soit on ne connaît pas la proportion d'individus ayant ce caractère dans la population. On prélève un échantillon de la population et on détermine la **fréquence** de ce caractère apparaissant dans l'échantillon. Cette fréquence nous permet d'estimer **un intervalle de confiance** dans lequel fluctue la **proportion p** du caractère dans la population totale. Cela permet, par exemple, de faire des sondages et d'estimer le pourcentage de vote pour un candidat, sur une population complète.

Définition 01 : Intervalle de fluctuation (p connue ou conjecturé)

Soit α un réel de l'intervalle $]0,1[$

L'intervalle de fluctuation au seuil de $100(1-\alpha)$ %, relatif aux échantillons de taille n , est l'intervalle centré autour de p qui contient la fréquence observée f dans un échantillon de taille n avec une probabilité égale à $1-\alpha$.

Définition 01 : Intervalle de confiance (p est inconnu)

Soit α un réel de l'intervalle $]0,1[$

L'intervalle de confiance au seuil de $100(1-\alpha)$ %, relatif aux échantillons de taille n , est l'intervalle centré autour de f où se situe la proportion p du caractère dans la population avec une probabilité égale à $1-\alpha$.

II. Rappels de seconde et de première S

1. Seconde

Soit p la proportion effective d'un caractère d'une population comprises entre 0,2 et 0,8 et f la fréquence du caractère dans un échantillon de taille n supérieure ou égale à 25. **L'intervalle de fluctuation** au seuil de 95 % ($\alpha = 0.05$) est

$$I_f = \left[p - \frac{1}{\sqrt{n}}; p + \frac{1}{\sqrt{n}} \right]$$

Soit f la fréquence observée d'un caractère d'un échantillon (de taille ≥ 25) comprises entre 0,2 et 0,8 et p la proportion du caractère dans la population.

L'intervalle de confiance au seuil de 95 % ($\alpha = 0.05$) est

$$I_p = \left[f - \frac{1}{\sqrt{n}}; f + \frac{1}{\sqrt{n}} \right]$$

Exemple 01 :

Dans un village de campagne à proximité d'industries chimiques, il est né entre l'année 2001 et 2005, 164 enfants dont 56 garçons.

Cela est-il normal ?

Exemple 02 :

Le 4 mai 2007, sit deux jours avant le second tour des élections présidentielles, on publie le sondage suivant réalisé auprès de 992 personnes :

Ségolène Royal : 45 % Nicolas Sarkozy : 55 %

Comment pouvez-vous interpréter ce sondage ?

2. Première S

Le tirage au hasard d'un individu dans une population est une épreuve de Bernoulli de paramètre p , où le succès est l'issue « avoir le caractère étudié »

Le prélèvement au hasard d'un échantillon de taille n dans cette population s'assimile dans à un schéma de Bernoulli de paramètre n et p .

La variable aléatoire X , qui compte le nombre d'individus ayant le caractère étudié, suit une loi Binomiale $B(n, p)$

La fréquence du caractère étudié dans l'échantillon est donc donnée par la variable

$$\text{aléatoire } F = \frac{X}{n}$$

Définition : Soit X une variable aléatoire qui suit la loi binomiale $B(n, p)$ et $F = \frac{X}{n}$ la variable aléatoire qui correspond à la fréquence f du caractère étudié.

L'intervalle de fluctuation de f au seuil 95 % fourni par la loi binomial est le plus petit

intervalle de la forme $\left[\frac{a}{n}; \frac{b}{n} \right]$ où a et b sont des entiers entre 0 et n tels que :

$$P\left(F < \frac{a}{n}\right) \leq 0,025 \text{ et } P\left(F > \frac{b}{n}\right) \leq 0,025 \text{ et donc } P\left(\frac{a}{n} \leq F \leq \frac{b}{n}\right) \geq 0,95$$

Remarque : Le prélèvement au hasard d'un échantillon de taille n consiste en n répétitions d'un tirage avec remise. Mais si les tirages s'effectuent sans remise, l'assimilation à un schéma de Bernoulli est encore possible lorsque la population est suffisamment grande en regard de n .

Définition : Soit f la fréquence observée d'un caractère d'un échantillon (de taille ≥ 25) comprises entre 0,2 et 0,8 et p la proportion du caractère dans la population. **L'intervalle de confiance** au seuil de 95 % ($\alpha = 0.05$) est

$$I_p = \left[f - \frac{1}{\sqrt{n}}; f + \frac{1}{\sqrt{n}} \right]$$

III. Théorème de Moivre-Laplace

Théorème

Soit n un entier naturel non nul et p une probabilité. On note X une variable aléatoire réelle qui suit une loi Binomiale $B(n, p)$.

Si on note $Z = \frac{X - np}{\sqrt{np(1-p)}}$ alors Z est une variable aléatoire centrée réduite et pour tous

réels a et b tels que $a \leq b$, on a : $\lim_{n \rightarrow +\infty} P(a \leq Z \leq b) = \int_a^b \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx$

En d'autres termes, lorsqu'on travaille sur un échantillon très grand, on peut faciliter ses calculs en remplaçant la loi binomiale par la loi normale (on parlera de convergence en loi). Z suit donc une loi normale centrée réduite.

En pratique, on considère que pour $n \geq 30$ l'approximation est valable. En classe de

terminale S on prendra comme conditions que $\begin{cases} n \geq 30 \\ np \geq 5 \\ np(1-p) \geq 5 \end{cases}$

IV. Intervalle de fluctuation asymptotique et intervalle de confiance en terminale S

Soit X_n une variable aléatoire suivant une loi binomiale $B(n, p)$ où $p \in]0; 1[$

On suppose que $n \geq 30$, $np \geq 5$ et $np(1-p) \geq 5$

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

D'après le théorème de Moivre-Laplace :

Z_n suit une loi

et

$$P(Z_n \in [-u_\alpha; u_\alpha]) =$$

$$\text{On pose } I_n = \left[p - u_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}}; p + u_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} \right]$$

Démontrez que $Z_n \in [-u_\alpha; u_\alpha] \Leftrightarrow \frac{X_n}{n} \in I_n$:

Définition :

L'intervalle $I_n = \left[p - u_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}}; p + u_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} \right]$ contient la fréquence $F_n = \frac{X_n}{n}$ avec une probabilité qui se rapproche de $1 - \alpha$ lorsque n augmente : On dit que c'est un intervalle de fluctuation asymptotique de F_n au seuil $1 - \alpha$

Prenons $\alpha = 0,05$ et donc $1 - \alpha = 0,95$

Quelle est la valeur de u_α ? $u_\alpha =$

Définition :

Soit X_n une variable aléatoire suivant une loi binomiale $B(n, p)$ où $p \in]0; 1[$

On suppose que $n \geq 30$, $np \geq 5$ et $np(1-p) \geq 5$

L'intervalle de fluctuation asymptotique au seuil de 95 % est donc :

$$I_n = \left[p - \dots\dots\dots \frac{\sqrt{p(1-p)}}{\sqrt{n}}; p + \dots\dots\dots \frac{\sqrt{p(1-p)}}{\sqrt{n}} \right]$$

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

2. Démontrer que pour tout $p \in]0;1[$, $p(1-p) \geq \frac{1}{4}$

3. En déduire que $P\left(p - \frac{1}{\sqrt{n}} \leq \frac{X_n}{n} \leq p + \frac{1}{\sqrt{n}}\right) \geq 0,95$

4. En déduire que $P\left(\frac{X_n}{n} - \frac{1}{\sqrt{n}} \leq p \leq \frac{X_n}{n} + \frac{1}{\sqrt{n}}\right) \geq 0,95$

Définition : Soit f la fréquence observée d'un caractère d'un échantillon (de taille ≥ 30) telle que $nf \geq 5$, $nf(1-f) \geq 5$ et p la proportion du caractère dans la population.

L'intervalle de confiance au niveau de confiance 0,95 est

$$I_p = \left[f - \frac{1}{\sqrt{n}} ; f + \frac{1}{\sqrt{n}} \right]$$

Précision d'une estimation :

Quelle est l'amplitude de l'intervalle de confiance au niveau 95 % ?

Conclusion :

Plus la taille de l'échantillon est grand et plus l'intervalle de confiance au niveau 95 % est