

Chapitre 9- INTERVALLE DE FLUCTUATION ET ESTIMATION

I – ECHANTILLONNAGE ET PRISE DE DECISION.

1- INTERVALLE DE FLUCTUATION ASYMPTOTIQUE.

Soit X_n la variable aléatoire suivant la loi binomiale $B(n; p)$.

Soit F_n la variable aléatoire qui associe la fréquence du caractère étudié dans l'échantillon aléatoire de taille n .

On a $F_n = \frac{X_n}{n}$. F_n représente alors la fréquence de succès pour un schéma de Bernoulli de paramètres n et p .

On admet que, pour n suffisamment grand, X_n suit approximativement la loi normale d'espérance mathématique $\mu = np$ et d'écart-type $\sigma = \sqrt{np(1-p)}$.

Dans le chapitre précédent que, on a vu : Si X_n suit une loi normale $N(\mu, \sigma^2)$,

$Z_n = \frac{X_n - \mu}{\sigma}$ suit la loi normale centrée réduite $N(0,1)$ et

$$P(-1,96 < Z_n < 1,96) \approx 0,95 \Leftrightarrow P(-1,96 < \frac{X_n - \mu}{\sigma} < 1,96) \approx 0,95$$

Donc

$$P(-1,96\sigma < X_n - \mu < 1,96\sigma) \approx 0,95$$
$$P(\mu - 1,96\sigma < X_n < \mu + 1,96\sigma) \approx 0,95$$
$$P\left(\frac{\mu - 1,96\sigma}{n} < \frac{X_n}{n} < \frac{\mu + 1,96\sigma}{n}\right) \approx 0,95$$

$$P\left(\frac{np - 1,96\sqrt{np(1-p)}}{n} < \frac{X_n}{n} < \frac{np + 1,96\sqrt{np(1-p)}}{n}\right) \approx 0,95$$

D'où :

$$P\left(p - 1,96\frac{\sqrt{p(1-p)}}{\sqrt{n}} < F_n < p + 1,96\frac{\sqrt{p(1-p)}}{\sqrt{n}}\right) \approx 0,95.$$

**PARTIE
A LIRE ET
A COMPRENDRE
MAIS NE PAS
RETENIR**

Soit F_n la variable aléatoire qui à tout échantillon de taille n associe la fréquence d'un caractère.

Posons $I_n = \left[p - 1,96\frac{\sqrt{p(1-p)}}{\sqrt{n}} ; p + 1,96\frac{\sqrt{p(1-p)}}{\sqrt{n}} \right]$ où p désigne la proportion de ce caractère dans la population.

Alors F_n prend ses valeurs dans I_n avec une probabilité qui s'approche de 0,95 quand n devient grand.

On pratique cette approximation dès que $n \geq 30$, $np \geq 5$ et $n(1-p) \geq 5$.

L'intervalle $I_n = \left[p - 1,96\frac{\sqrt{p(1-p)}}{\sqrt{n}} ; p + 1,96\frac{\sqrt{p(1-p)}}{\sqrt{n}} \right]$ est appelé **intervalle de fluctuation asymptotique au seuil de 95%**.

A RETENIR

Aller voir vidéo : <https://www.youtube.com/watch?v=ycWtHDGTLmM&t=241s>

Application : (Révision des 3 intervalles de fluctuation étudiés en lycée)

On considère un dé cubique supposé équilibré. On désigne par X la variable aléatoire associant à chaque échantillon de 100 lancers le nombre de 6 obtenus. On pose $F = \frac{X}{100}$ la variable aléatoire fréquence.

1. Déterminer l'intervalle de fluctuation de la variable aléatoire F au seuil de 95 % vu en Première.
2. Déterminer l'intervalle de fluctuation asymptotique de la variable aléatoire F au seuil de 95 % (arrondir les bornes à 10^{-3}). Interpréter le résultat obtenu.
3. Déterminer l'intervalle de fluctuation de la variable aléatoire F au seuil de 95 % vu en classe de Seconde. (Arrondir les bornes à 10^{-2}).
4. Comparer les trois intervalles.

ATTENTION : Pour les valeurs approchées des bornes : règle : pour la borne inférieure, on prend la valeur approchée par défaut et pour la borne supérieure, la valeur approchée par excès.

SOLUTION

1. X suit la loi binomiale de paramètres $n = 100$ et $p = \frac{1}{6}$.

La calculatrice ou un logiciel (ici un tableur) permet de constater que :

• $P(X \leq 9) \approx 0,021$ et $P(X \leq 10) \approx 0,043$

• $P(X \leq 23) \approx 0,962$ et $P(X \leq 24) \approx 0,978$.

Le plus petit entier a tel que $P(X \leq a) > 0,025$ est donc $a = 10$ et le plus petit entier b tel que $P(X \leq b) \geq 0,975$ est $b = 24$. L'intervalle de fluctuation de la variable aléatoire F

au seuil de 95 % est donc $\left[\frac{a}{n}; \frac{b}{n}\right] = [0,1; 0,24]$.

2. $p - 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}} = \frac{1}{6} - 1,96 \frac{\sqrt{\frac{1}{6} \times \frac{5}{6}}}{\sqrt{100}} \approx 0,094$ et de même $p + 1,96 \frac{\sqrt{p(1-p)}}{\sqrt{n}} \approx 0,240$.

L'intervalle de fluctuation asymptotique de la variable aléatoire F au seuil de 95 % est donc, en arrondissant les bornes à 10^{-3} , l'intervalle $[0,094; 0,240]$.

3. $p - \frac{1}{\sqrt{n}} = \frac{1}{6} - \frac{1}{\sqrt{100}} \approx 0,067$ et $p + \frac{1}{\sqrt{n}} = \frac{1}{6} + \frac{1}{\sqrt{100}} \approx 0,267$. En classe de Seconde, on aurait donc obtenu l'intervalle $[0,067; 0,267]$ comme intervalle de fluctuation de la variable F au seuil de 95 %.

4. On constate que les intervalles des classes de Première et de Terminale sont très proches, le second étant plus simple à déterminer que le premier. L'intervalle de la classe de Seconde est certes très simple à calculer mais il est bien plus large

	A	B
9	8	0,0095
10	9	0,0213
11	10	0,0427
12	11	0,0777
13	12	0,1297
23	22	0,9369
24	23	0,9621
25	24	0,9783
26	25	0,9881

2- PRISE DE DECISION A PARTIR D'UN ECHANTILLON.

Voir la vidéo : <https://www.youtube.com/watch?v=QZ0YFthGI0Y>

La détermination d'un intervalle de fluctuation permet de prendre une décision lorsque **la proportion du caractère étudié dans la population est supposée être égale à p** .

La prise de décision consiste, à partir d'un échantillon de taille n , à valider ou non, cette hypothèse faite sur p .

En pratique :

- On calcule la fréquence observée f du caractère étudié dans l'échantillon.
- Puis, **si $n \geq 30$, $np \geq 5$ et $n(1-p) \geq 5$** , on détermine l'intervalle I de fluctuation asymptotique au seuil de 95% défini précédemment. (*Les conditions seront toujours vérifiées pour utiliser cet intervalle !!!*)

- Enfin, on applique la règle suivante :

REGLE DE DECISION :

Soit I l'intervalle de fluctuation de la fréquence à 95% dans les échantillons de taille n

- Si la fréquence observée f appartient à I : on accepte l'hypothèse faite sur la proportion p au seuil de risque de 5%.
- Si la fréquence observée f n'appartient pas à I , on rejette l'hypothèse faite sur la proportion p au seuil de 5%.

Application :

L'organisateur d'une tombola prétend que la proportion des tickets gagnants est $p = 0,1$.

Pour vérifier son hypothèse, on prélève au hasard un échantillon de 400 tickets.

On considère que le nombre total de tickets est suffisamment grand pour que le tirage soit assimilé à un tirage avec remise.

1. Sous l'hypothèse $p = 0,1$, déterminer l'intervalle de fluctuation asymptotique au seuil de 95 % de la variable aléatoire correspondant à la fréquence des tickets gagnants dans un échantillon de taille 400. (Arrondir les bornes de l'intervalle à 10^{-3}).

2. Énoncer la règle de décision permettant de rejeter, ou non, l'hypothèse $p = 0,1$, au seuil de décision de 5 % sur un échantillon aléatoire de taille 400.

3. L'échantillon prélevé comporte 25 tickets gagnants. Que peut-on conclure ?

SOLUTION

1. Avec $p_0 = 0,1$ et $n = 400$, on a $p_0 - 1,96 \frac{\sqrt{p_0(1-p_0)}}{\sqrt{n}} \approx 0,070$ et $p_0 + 1,96 \frac{\sqrt{p_0(1-p_0)}}{\sqrt{n}} \approx 0,130$

Sous l'hypothèse $p = 0,1$, l'intervalle de fluctuation asymptotique au seuil de 95 % de la variable aléatoire donnant la fréquence des tickets gagnants sur un échantillon de taille 400 est l'intervalle : $I = [0,070 ; 0,130]$

2. La règle de décision, au seuil de décision de 5 %, est la suivante : on calcule la fréquence f des tickets gagnants sur un échantillon aléatoire de taille 400. Si $f \notin I$, on rejette l'hypothèse $p = 0,1$; si $f \in I$, on ne la rejette pas.

3. Comme $f = \frac{25}{400} = 0,0625$ n'appartient pas à l'intervalle I , on rejette l'hypothèse $p = 0,1$ au seuil de décision 5 %.
(Ou au seuil de 95%)

II- ESTIMATION D'UNE PROPORTION.

L'**estimation** consiste à déterminer le mieux possible la proportion p **inconnue** d'un caractère dans la population toute entière, connaissant la fréquence f observée de ce caractère dans un échantillon extrait de cette population. Ce problème d'estimation se pose en particulier dans les sondages.

Aller voir vidéo : <https://www.youtube.com/watch?v=cU5cJICVAM8>

Propriété : Soit F_n la variable aléatoire fréquence, qui, à tout échantillon de taille n extrait d'une population dans lequel la proportion est p , associe la fréquence donnée.

Alors l'intervalle $[F_n - \frac{1}{\sqrt{n}} ; F_n + \frac{1}{\sqrt{n}}]$ contient, pour n assez grand, la proportion p avec une probabilité au moins égale à 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 . Alors l'intervalle $[f - \frac{1}{\sqrt{n}} ; f + \frac{1}{\sqrt{n}}]$ est un **intervalle de confiance** de la proportion p **au niveau de confiance 0,95**. **A RETENIR**

Remarques : 1) Cet intervalle est soumis aux 3 mêmes conditions que celles de l'intervalle de fluctuation. On considèrera qu'elles seront vérifiées.

2) Cet intervalle a une amplitude de $\frac{2}{\sqrt{n}}$ (En effet : $f + \frac{1}{\sqrt{n}} - (f - \frac{1}{\sqrt{n}}) = \frac{1}{\sqrt{n}} + \frac{1}{\sqrt{n}} = \frac{2}{\sqrt{n}}$)

Application : Sur un échantillon de 400 personnes, 73 ont vu un certain spot publicitaire à la télévision.

1) Au niveau de confiance de 95%, dans quel intervalle se trouve le pourcentage de ceux qui ont vu le spot dans la population totale ?

$$f = \frac{73}{400} ; n = 400 \quad \text{donc } I_c = \left[\frac{73}{400} - \frac{1}{\sqrt{400}} ; \frac{73}{400} + \frac{1}{\sqrt{400}} \right] ; I_c = [0,1325 ; 0,2325]$$

Voir la vidéo : <https://www.youtube.com/watch?v=ogmMVpkBVgs>

2) Combien faudrait-il interroger de personnes pour que cet intervalle ait une amplitude inférieure à 2% ?

On résout : $\frac{2}{\sqrt{n}} < 0,02 \Leftrightarrow 2 < 0,02 \sqrt{n} \Leftrightarrow 100 < \sqrt{n} \Leftrightarrow 1000 < n$

Pour que l'intervalle ait une amplitude inférieure à 2%, il faut interviewer **au moins 1000 personnes**.

POUR Y VOIR CLAIR ENTRE INTERVALLE DE FLUCTUATION ET INTERVALLE DE CONFIANCE :

Aller voir la vidéo : <https://www.youtube.com/watch?v=97vzxWsvie8>

CONCLUSION : (Tout est résumé ici)

REGLE GENERALE :

- On utilise un **intervalle de fluctuation** lorsque la **proportion p dans la population est connue** ou si l'on fait une **hypothèse sur sa valeur**.
- On utilise un **intervalle de confiance** lorsque l'on veut estimer une **proportion p inconnue** dans une population.

BILAN :

Bien que ces deux notions soient voisines, il ne faut pas confondre proportion p et fréquence f :

- La **proportion** est une valeur statistique (théorique), **sur l'ensemble de la population**
- La **fréquence** est la proportion observée **sur un échantillon de la population**

Intervalle de fluctuation

Ce qui est connu ou supposé:

- probabilité (proportion) p ,
- taille de l'échantillon n

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

But : Estimer une fréquence f à partir d'une probabilité.

Construire un intervalle à l'aide de la probabilité p centré, contenant les fréquences observées à 95%.

La proportion dans la population est connue (ou supposée).

On tire un échantillon. La proportion dans l'échantillon ne sera que par hasard égale à celle de la population. En général la proportion dans l'échantillon sera différente, mais la plupart du temps (dans 95 % des cas par exemple) elle ne sera pas trop différente de la proportion dans la population.

L'intervalle de fluctuation est l'intervalle dans lequel on trouve (pour 95 % des cas) la proportion dans l'échantillon ; cet intervalle est calculé à partir de la proportion dans la population qui est connue.

Intervalle de confiance

Ce qui est connu :

- fréquence f
- taille de l'échantillon n

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

But : Estimer une proportion (probabilité) p à partir des observations.

Construire un intervalle à l'aide de la fréquence f contenant la probabilité (ou la proportion inconnue) avec un niveau de confiance de 95%.

La proportion dans la population est inconnue.

On tire un échantillon. On compte la proportion dans l'échantillon. On se demande s'il est possible d'estimer à partir de cette valeur connue par l'échantillon, la valeur inconnue de la proportion dans la population. On sait bien qu'il est tout à fait possible que l'estimation soit fautive. On calcule un intervalle pour la proportion dans la population : c'est l'intervalle de confiance. Avec la formule que tu emploies on trouve un intervalle qui encadre bien la valeur inconnue de la population dans 95 % des cas.