

Chapitre :

Fluctuation



I. Retour sur la loi normale

Propriété | Soit X une variable aléatoire qui suit la loi normale centrée réduite $\mathcal{N}(0; 1)$. Pour tout réel $\alpha \in]0; 1[$, il existe un unique réel t_α tel que $\mathbb{P}(-t_\alpha \leq X \leq t_\alpha) = 1 - \alpha$.

Démonstration (exigible) : On considère f , la densité de probabilité de la loi $\mathcal{N}(0; 1)$.

Soit $H : t \mapsto \int_0^t f(x)dx$. Alors (par symétrie) $\mathbb{P}(-t \leq X \leq t) = 2\mathbb{P}(0 \leq X \leq t) = 2H(t)$.

La fonction H est la primitive de f sur \mathbb{R} qui s'annule en 0.

La fonction f étant positive sur $[0; +\infty[$, H est donc continue et strictement croissante sur $[0; +\infty[$.

Or, par symétrie de la courbe, $\lim_{t \rightarrow +\infty} H(t) = \mathbb{P}(X \geq 0) = \frac{1}{2}$.

Par suite, la fonction $2H$ est continue, strictement croissante sur $[0; +\infty[$, et ses valeurs sont comprises entre $2 \times 0 = 0$ et $2 \times \frac{1}{2} = 1$.

Soit $\alpha \in]0; 1[$. Alors $1 - \alpha$ appartient aussi à $]0; 1[$. D'après le corollaire du théorème des valeurs intermédiaires, il existe donc un unique réel t_α strictement positif tel que $2H(t_\alpha) = 1 - \alpha$, autrement dit tel que $\mathbb{P}(-t_\alpha \leq X \leq t_\alpha) = 1 - \alpha$. \square

Propriété | Avec les notations précédentes,

- Pour $\alpha = \frac{5}{100} = 0,05$, alors $t_\alpha \simeq 1,96$
- Pour $\alpha = \frac{1}{100} = 0,01$, alors $t_\alpha \simeq 2,58$

Autrement dit :

$$\mathbb{P}(-1,96 \leq X \leq 1,96) \simeq 0,95 \quad \text{et} \quad \mathbb{P}(-2,58 \leq X \leq 2,58) \simeq 0,99$$

Démonstration : Exercice

Il s'agit de se ramener à la recherche de x tel que $\mathbb{P}(X \leq x) = p$ (p étant donné), dont la calculatrice donne une valeur approchée. \square

Remarque Parfois on utilise la notation u_α à la place de t_α .

II. Intervalle de fluctuation asymptotique

⊗ **Activité** : 1p356, en groupe, en salle informatique, en utilisant le fichier de tableur associé.

Soit, pour tout $n \in \mathbb{N}$, X_n une variable aléatoire qui suit la loi binomiale $\mathcal{B}(n, p)$. On pose alors

$F_n = \frac{X_n}{n}$, fréquence de succès.

Propriété Avec les notations de la section précédente,

pour tout $\alpha \in]0; 1[$, on définit l'intervalle $I_n = \left[p - t_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}}; p + t_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} \right]$.

Alors

$$\lim_{n \rightarrow +\infty} \mathbb{P}(F_n \in I_n) = 1 - \alpha$$

Démonstration (exigible) : On réécrit :

$$\begin{aligned} F_n \in I_n &\Leftrightarrow p - t_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq \frac{X_n}{n} \leq p + t_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} \\ &\Leftrightarrow np - t_\alpha \frac{n\sqrt{p(1-p)}}{\sqrt{n}} \leq X_n \leq np + t_\alpha \frac{n\sqrt{p(1-p)}}{\sqrt{n}} \\ &\Leftrightarrow np - t_\alpha \sqrt{np(1-p)} \leq X_n \leq np + t_\alpha \sqrt{np(1-p)} \\ &\Leftrightarrow -t_\alpha \leq Z_n \leq t_\alpha \text{ en posant } Z_n = \frac{X_n - np}{\sqrt{np(1-p)}} \end{aligned}$$

Ainsi, $\mathbb{P}(F_n \in I_n) = \mathbb{P}(-t_\alpha \leq Z_n \leq t_\alpha)$.

Or, d'après le théorème de Moivre-Laplace, $\lim_{n \rightarrow +\infty} \mathbb{P}(-t_\alpha \leq Z_n \leq t_\alpha) = \int_{-t_\alpha}^{t_\alpha} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx$.

Or $\int_{-t_\alpha}^{t_\alpha} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx = \mathbb{P}(-t_\alpha \leq Y \leq t_\alpha)$ où Y suit la loi normale centrée réduite $\mathcal{N}(0; 1)$.

Ainsi on a bien

$$\lim_{n \rightarrow +\infty} \mathbb{P}(F_n \in I_n) = 1 - \alpha$$

□

Définition L'intervalle $I_n = \left[p - t_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}}; p + t_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} \right]$ est un **intervalle de fluctuation asymptotique au seuil de confiance $1 - \alpha$** de la variable aléatoire fréquence F_n qui, à tout échantillon de taille n , associe la fréquence obtenue.

Cet intervalle contient F_n avec une probabilité d'autant plus proche de $1 - \alpha$ que n est grand.

On considère que c'est le cas lorsque $n \geq 30$, $np \geq 5$ et $n(1-p) \geq 5$.

On considère en général l'intervalle asymptotique au seuil de confiance 95%, donc avec $\alpha = 0,05$.

Il s'agit de l'intervalle :

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

► **Exercice :** 1p364 (vérification des conditions)

► **Exercices :** 2,4p364, 15,16p365 (seuil 95%)

► **Exercices :** 5,6p364, 19p365 (seuil 99%)

► **Exercices :** 20,21p365 (autres seuils)

► **Exercices :** 23,24p366 (algorithmes)

III. Prise de décision

⊗ **Activité** : 2p356 (avec vrai intervalle pour la loi binomiale)

Pour décider si une fréquence f observée sur un échantillon de taille n est compatible ou non avec une proportion p donnée pour la population totale, on teste l'appartenance de f à un intervalle de fluctuation (asymptotique ou non) au seuil de 95%. Par suite,

- Si f n'est pas dans l'intervalle de fluctuation, alors on peut rejeter l'hypothèse que l'échantillon est compatible avec le modèle.
- Si f est dans l'intervalle de fluctuation, alors on accepte l'hypothèse que l'échantillon est compatible avec le modèle.

Remarque Quelle que soit la décision prise il y a toujours le risque que ce ne soit pas la bonne décision.

 Pour utiliser l'intervalle de fluctuation asymptotique, il faut que les conditions soient vérifiées!

Remarque On peut prendre des décisions avec des seuils différents (voir page 360).

► **Exercices** : 8p364, 27p366

► **Exercices** : 30p366, 31p367 (conditions non vérifiées)

IV. Estimation

L'intervalle de fluctuation s'utilise lorsque l'on connaît la proportion p dans la population totale. On s'intéresse ici au problème « inverse », c'est à dire qu'à partir d'une fréquence f observée, on veut pouvoir estimer la proportion p . C'est le problème posé pour les sondages par exemple.

Propriété Soit, pour tout $n \in \mathbb{N}$, X_n une variable aléatoire qui suit la loi $\mathcal{B}(n, p)$, avec $p \in]0; 1[$. Alors il existe un entier n_0 tel que pour tout $n \geq n_0$,

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

Démonstration : (davantage détaillée page 362). On pose $Z_n = \frac{X_n - np}{\sqrt{np(1-p)}}$.

D'après le théorème de Moivre-Laplace, en posant $a_n = \mathbb{P}(-2 \leq Z_n \leq 2)$, on a

$\lim_{n \rightarrow +\infty} a_n = \mathbb{P}(-2 \leq Z \leq 2)$, où Z suit la loi normale centrée réduite $\mathcal{N}(0; 1)$.

Notons $L = \mathbb{P}(-2 \leq Z \leq 2)$. On peut obtenir $L \leq 0,9544$, soit $L > 0,95$.

Soit $\epsilon > 0$ tel que $\epsilon < 0,004$. Puisque la suite $(a_n)_{n \in \mathbb{N}}$ a pour limite L , il existe un entier n_0 tel que pour tout $n \geq n_0$, $a_n \in]L - \epsilon; L + \epsilon[$, autrement dit $L - \epsilon < a_n < L + \epsilon$.

En particulier, $a_n > 0,95$.

$$\text{Or, } a_n = \mathbb{P}(-2 \leq Z_n \leq 2) = \mathbb{P}\left(p - 2 \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq \frac{X_n}{n} \leq p + 2 \frac{\sqrt{p(1-p)}}{\sqrt{n}}\right)$$

La fonction $\phi : p \mapsto p(1 - p)$, polynomiale de degré 2, admet un maximum en $\frac{1}{2}$, qui vaut $\frac{1}{4}$.

Ainsi, $p(1 - p) \leq \frac{1}{4}$, d'où $\sqrt{p(1 - p)} \leq \frac{1}{2}$ puis $2 \frac{\sqrt{p(1 - p)}}{\sqrt{n}} \leq \frac{1}{\sqrt{n}}$.

Par conséquent, $\left[p - 2 \frac{\sqrt{p(1 - p)}}{\sqrt{n}}; p + 2 \frac{\sqrt{p(1 - p)}}{\sqrt{n}} \right] \subset \left[p - \frac{1}{\sqrt{n}}; p + \frac{1}{\sqrt{n}} \right]$.

Finalement, $\mathbb{P} \left(p - \frac{1}{\sqrt{n}} \leq \frac{X_n}{n} \leq p + \frac{1}{\sqrt{n}} \right) \geq a_n > 0,95$. □

Propriété Avec les notations précédentes, on pose $F_n = \frac{X_n}{n}$.

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

Démonstration : Il suffit d'appliquer la propriété précédente, en observant que

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

□

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

On considère que les conditions pour utiliser cet intervalle sont : $n \geq 30$, $nf \geq 5$ et $n(1 - f) \geq 5$, soit les mêmes que pour l'intervalle de fluctuation en remplaçant p par f .

Remarque Il s'agit de l'intervalle de confiance qui a pu être vu en seconde.

Remarque Il existe d'autres intervalles de confiance, comme :

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

qu'il n'est pas possible de justifier en terminale S.

► **Exercices** : 10,12p364 et 35,39p367

► **Exercices** : 43,44,45,46p368 (amplitude de l'intervalle, détermination de n)