

Échantillonnage

Plan de ce chapitre

I.	Introduction	2
II.	Intervalle de fluctuation	3
II. 1.	Échantillon	3
II. 2.	Intervalle de fluctuation au seuil de 95%	4
II. 3.	Prise de décision	4

I. Introduction

Nous allons considérer l'expérience consistant à lancer un dé cubique supposé non truqué. On pose alors :

A : « obtenir le 1 ».

Nous allons effectuer une simulation de 100 lancers de dé à l'aide d'un tableur.

Ouvrons un tableur et entrons dans la cellule A1 la formule suivante :

	A	B	C
1	=ENT(1+6*ALEA())		
2			

- La fonction ALEA() permet de calculer un nombre aléatoire compris entre 0 (compris) et 1 (non compris);
- $6 * \text{ALEA}()$ affichera donc un nombre dans l'intervalle $[0;6[$;
- $1 + 6 * \text{ALEA}()$ affichera donc un nombre dans l'intervalle $[1;7[$;
- La fonction ENT calcule la partie entière d'un nombre; donc $\text{ENT}(1 + 6 * \text{ALEA}())$ affichera un nombre entier parmi : 1, 2, 3, 4, 5 et 6.

Maintenant, copions cette formule de A2 à A100 afin d'obtenir, au final, 100 nombres entiers compris entre 1 et 6.

Dans la cellule A101, entrons la formule :

$$=\text{NB.SI}(A1:A100;1)$$

Elle affichera le nombre de « 1 » qui apparaissent dans la colonne A.

Ensuite, entrons dans la cellule A102 la formule :

$$=A101/100$$

pour afficher la fréquence d'apparition du nombre « 1 » dans la colonne A.


Copions alors la colonne A dans les colonnes de B à BG afin d'obtenir au final 60 colonnes de nombres.

Ceci simule 60 échantillons de 100 lancers d'un dé cubique (60 échantillons de taille $n = 100$).

On construit alors un nuage de points représentant les différentes fréquences obtenues.

En appuyant sur la touche [F9], on rafraîchit les calculs et on obtient un autre graphique.

Voici un des graphiques obtenus :



La fréquence d'apparition théorique du nombre « 1 » est la probabilité d'obtenir ce nombre :

$$p = \frac{1}{6} \approx 0,17.$$

On s'aperçoit alors sur le graphique que les fréquences semblent se regrouper autour de cette valeur. On peut donc imaginer que les fréquences d'apparition du nombre « 1 » vont se trouver dans un intervalle centré en p : un intervalle de la forme $I = [p - \delta; p + \delta]$.

Nous allons prendre $\delta = \frac{1}{\sqrt{n}} = \frac{1}{\sqrt{100}} = 0,1$. Alors, $I \approx [0,066; 0,267]$.

Pour connaître le pourcentage de fréquences comprises dans cet intervalle, insérons dans la cellule A103 la formule :

$$=SI(A102<=0,266;SI(A102>0,067;1;0);0)$$

qui affiche « 1 » si tel est le cas, et « 0 » sinon. Ensuite, copions-la sur toute la ligne 103 jusqu'à BH103.

Dans la cellule A104, insérons la formule :

$$=SOMME(A103:BH103)/60$$

puis formatons cette cellule de sorte à ce qu'elle affiche un pourcentage (en cliquant sur l'icône « % ») : ceci affichera le pourcentage de fréquences d'apparition du « 1 » qui sont dans I.

En appuyant sur la touche [F9] plusieurs fois, je vois les pourcentages suivants :

100% ; 96,67% ; 98,33% ; 100% ; 100% ; 98,33%.

En utilisant donc cette valeur de δ , nous sommes *a priori* assurés qu'au moins 95% des fréquences se trouvent dans I.

II. Intervalle de fluctuation

II. 1. Échantillon

Déf.1 Soit une population dans laquelle on observe un groupe de n individus. Ce groupe est appelé un **échantillon de taille n** de la population.

Exemple 1

Dans l'expérience précédente, qui consiste à lancer 100 fois un dé cubique, l'échantillon était de taille 100 car on a effectué 100 lancers de dés (que l'on a ensuite répété 60 fois).

II. 2. Intervalle de fluctuation au seuil de 95%

Définition 2

On considère une expérience aléatoire dans laquelle on considère un événement A de probabilité p . On effectue n fois cette expérience; on note alors f la fréquence d'apparition de l'événement A sur cet échantillon de taille n .

Un **intervalle de fluctuation au seuil de 95%** de f , noté I_f , est un intervalle centré en p qui contient f dans un échantillon de taille n avec une probabilité égale à 0,95 :

$$I_f = [p - \delta; p + \delta] \quad (\delta > 0) \quad \text{et} \quad P(f \in I_f) = 0,95.$$



À retenir

Un intervalle de fluctuation n'est pas unique car il y a plusieurs valeurs possible de δ .

Propriété 1

Considérons un échantillon de taille n et posons p la probabilité d'obtenir un résultat précis. Notons f la fréquence d'apparition de ce résultat dans l'échantillon.

Pour $0,2 \leq p \leq 0,8$ et $n \geq 25$, un intervalle de fluctuation au seuil de 95% est :

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

II. 3. Prise de décision

On utilise les intervalles de fluctuations pour déterminer si l'on peut considérer qu'un événement est « normal » ou pas.

Exemple 2

On lance 100 fois un dé tétraédrique (4 faces) et on observe que la fréquence d'apparition de la face « 3 » est $f = 0,32$. On peut donc se demander si le dé n'est pas truqué car la fréquence observé est plus grande que la probabilité de l'événement, à savoir $p = \frac{1}{4} = 0,25$.

Un intervalle de fluctuation au seuil de 95% est :

$$I_f = \left[0,25 - \frac{1}{\sqrt{100}}; 0,25 + \frac{1}{\sqrt{100}} \right] = [0,15; 0,35].$$

On constate alors que $f \in I_f$, ce qui nous permet de dire que le dé n'est probablement pas truqué.

En revanche, si $f = 0,29$ sur 10 000 lancers, l'intervalle de fluctuation devient :

$$I'_f = \left[0,25 - \frac{1}{\sqrt{10\,000}}; 0,25 + \frac{1}{\sqrt{10\,000}} \right] = [0,24; 0,26].$$

Dans ce cas, $f \notin I'_f$, ce qui nous permet de dire que le dé est probablement truqué.