

◆ Chapitre 16. — Échantillonnage

Dans tout ce qui suit, on s'intéresse à une expérience aléatoire et on note A un événement relatif à cette expérience. Une loi de probabilité sur l'univers ayant été choisie pour modéliser l'expérience, on note p la probabilité de l'évènement A .

1 Fluctuation d'échantillonnage

Définition 1. — Soit n un entier naturel non nul. Un échantillon de taille n de l'expérience aléatoire est une série de résultats obtenus en réalisant n fois l'expérience aléatoire dans les mêmes conditions.

À un tel échantillon, on associe la fréquence f de A définie par $f = \frac{n_A}{n}$ où n_A est le nombre de fois où A a été réalisé lors des n expériences effectuées.

Exemple. — On lance un dé équilibré et on considère l'évènement A : « obtenir un nombre supérieur ou égal à 5 ». On modélise l'expérience par l'équiprobabilité sur $\{1, 2, 3, 4, 5, 6\}$.

Si on lance 20 fois ce dé, on obtient un échantillon de taille 20 de l'expérience. Si les résultats sont

5 – 6 – 2 – 3 – 4 – 4 – 6 – 5 – 3 – 1 – 5 – 2 – 3 – 2 – 2 – 4 – 3 – 3 – 1 – 2

alors $n_A = 5$ et la fréquence de A est $f = \frac{5}{20} = \frac{1}{4}$.

Si on relance 20 fois ce même dé, on obtient un autre échantillon, par exemple :

5 – 4 – 5 – 6 – 2 – 3 – 2 – 6 – 4 – 1 – 5 – 3 – 1 – 6 – 5 – 6 – 4 – 3 – 6 – 5.


Pour ce second échantillon, $n_A = 10$ et la fréquence de A est $f = \frac{10}{20} = \frac{1}{2}$.

Lorsqu'on considère plusieurs échantillons et qu'on calcule, pour chaque échantillon, la fréquence du même évènement A , on trouve en général des fréquences différentes et cela même si les échantillons ont la même taille. Ainsi, la fréquence de A varie en fonction de l'échantillon. Ce phénomène est appelé la **fluctuation d'échantillonnage**.

2 Loi faible des grands nombres

Cependant, malgré la fluctuation d'échantillonnage, lorsqu'on calcule la fréquence de l'évènement A sur des échantillons dont les tailles sont de plus en plus grandes, les résultats obtenus tendent à se stabiliser et à se rapprocher de la probabilité théorique p de l'évènement A .

Exemple. — Pour n compris entre 1 et 20 000, on a simulé des échantillons de taille n d'un lancer de dé et calculer la fréquence de l'évènement « Obtenir un nombre supérieur ou égal à 5 ». Le graphique ci-dessous donne cette fréquence en fonction de n . La droite horizontale est la droite d'équation $y = p$ c'est-à-dire ici $y = \frac{1}{3}$.



On voit sur ce graphique que, pour cet échantillon, effectivement la fréquence observée se rapproche de la probabilité théorique lorsque n augmente.

C'est un résultat général appelé loi faible des grands nombres qu'on peut résumer ainsi : « Lorsque n est grand, sauf exception, la fréquence f est proche de la probabilité p ». Il faut comprendre le « sauf exception » de la manière suivante : si on considère différents échantillons de taille n avec n grand, il est rare de tomber sur un échantillon pour lequel f diffère sensiblement de p et cela est d'autant plus rare que n grand.

On peut estimer cette « rareté » à l'aide de fonctions Python.

```

from random import *
from math import *

def fréquence(n):
    c=0
    for i in range(n):
        a=randint(1,6)
        if (a>=5):
            c+=1
    return(c/n)

def nb_écart(n,m,e):
    nb=0
    for i in range(m):
        f=fréquence(n)
        if (abs(1/3-f)>e):
            nb+=1
    return(nb)

```

La fonction `fréquence(n)` simule un échantillon de taille n d'un lancer de dé équilibré et renvoie la fréquence de l'évènement A : « obtenir un nombre supérieur ou égal à 5 ». La fonction `nb_écart(n,m,e)` simule m échantillons de taille n d'un lancer de dé et renvoie le

nombre d'échantillons pour lesquels la fréquence f de A diffère de la probabilité théorique $\frac{1}{3}$ de plus de e . On appellera ces échantillons des échantillons *exceptionnels*.

Voici les résultats obtenus pour $m=1000$ et différentes valeurs de n et e

e \ n	50	100	500	1000	5000	10000
0,5	0	0	0	0	0	0
0,1	147	39	0	0	0	0
0,05	450	279	16	1	0	0
0,01	882	820	659	504	121	34

Ainsi, par exemple, pour $n=500$ et $e=0,05$, on a trouvé 16 ce qui signifie que sur les 1000 échantillons de taille 500, 16 donnaient une fréquence différentes de $\frac{1}{3}$ de plus de 0,5 (en plus ou en moins).

On voit que, pour une précision donnée, plus on augmente la taille de l'échantillon, plus le nombre d'échantillons *exceptionnels* diminue et plus on augmente la précision (c'est-à-dire plus on diminue e), plus le nombre d'échantillons *exceptionnels* augmente.

La loi faible des grands nombres dit précisément que, pour une précision donnée, la probabilité de tomber sur un échantillon *exceptionnels* tend vers 0 lors n augmente indéfiniment.

Pour finir, on peut montrer qu'en général, pour des échantillons de taille n , f appartient à l'intervalle $\left[p - \frac{1}{\sqrt{n}}; p + \frac{1}{\sqrt{n}}\right]$ dans au moins 95% des cas.

Ceci peut se vérifier expérimentalement. Voici les résultats obtenus grâce à la fonction `nb_écart`, toujours avec $m=1000$ et pour différentes valeurs de n en prenant $e=\frac{1}{\sqrt{n}}$:

n	100	500	1000	5000	10000
nombre d'échantillons exceptionnels	42	26	36	28	41

Ainsi, on obtient entre $\frac{28}{1000} = 2,8\%$ et $\frac{42}{1000} = 4,2\%$ d'échantillons *exceptionnels*. Ainsi, dans tous les cas, les échantillons *exceptionnels* représentent moins de 5% des échantillons.