

## Adéquation à une loi équirépartie

Une *loi équirépartie* est une loi uniforme d'une variable aléatoire  $X$  qui peut prendre  $n$  valeurs de telle sorte que la probabilité soit la même pour chacune de ces  $n$  valeurs.

**Problème :** *Un joueur veut vérifier si le dé qu'il possède est « normal », c'est-à-dire bien équilibré.*

On sait que, dans ce cas-là, la loi de probabilité associée est la loi uniforme :

$$P(\{1\}) = P(\{2\}) = \dots = P(\{6\}) = \frac{1}{6}$$

Pour cela, le joueur lance 200 fois le dé et note les résultats obtenus :

$x_i$	1	2	3	4	5	6
$n_i$	31	38	40	32	28	31
$f_i$	0,155	0,190	0,200	0,160	0,140	0,155

Pour savoir si la distribution de fréquences obtenue est « proche » de la loi uniforme, on calcule la quantité suivante, qui prend en compte l'écart existant entre chaque fréquence trouvée et la probabilité théorique attendue :

$$d^2 = \left(0,155 - \frac{1}{6}\right)^2 + \left(0,190 - \frac{1}{6}\right)^2 + \left(0,200 - \frac{1}{6}\right)^2 + \left(0,160 - \frac{1}{6}\right)^2 + \left(0,140 - \frac{1}{6}\right)^2 + \left(0,155 - \frac{1}{6}\right)^2.$$

(On note  $d^2$  car son calcul est celui du carré d'une distance)

Mais rien ne permet de dire pour l'instant si cette quantité trouvée est « petite » ou « grande ». En effet, elle est soumise à la fluctuation d'échantillonnage, puisque sa valeur varie d'une série de lancers à l'autre. On va donc étudier cette fluctuation d'échantillonnage pour convenir d'un seuil entre « petite » et « grande » valeur de  $d^2$  lorsqu'on lance 200 fois un dé. Pour cela, on génère des séries de 200 chiffres au hasard pris dans  $\{1; 2; 3; 4; 5; 6\}$ . Les résultats trouvés pour le nombre  $d^2$  à partir de 1 000 simulations sont résumés par le tableau suivant :

Minimum	D <sub>1</sub>	Q <sub>1</sub>	Médiane	Q <sub>3</sub>	D <sub>9</sub>	Maximum
0,000363	0,00138	0,00233	0,00363	0,00555	0,00789	0,01658

Le **neuvième décile** de la série des valeurs simulées de  $d^2$  est 0,00789.

Cela signifie que 90 % des valeurs de  $d^2$  obtenues au cours de ces 1 000 simulations sont dans l'intervalle  $[0; 0,00789]$ . Comme la valeur observée de  $d^2$  est inférieure à cette valeur seuil de 0,00789, on peut convenir que le dé est équilibré avec un risque de 10 %.

En effet, en utilisant cette méthode sur les données simulées, on se serait trompé dans 10 % des cas. On dit que l'on a un **seuil de confiance** de 90 %.

**Propriété :** Soit une épreuve conduisant aux issues  $a_1, a_2, \dots, a_q$ . Expérimentalement, si on répète  $n$  fois cette épreuve ( $n \geq 100$ ), on obtient les fréquences  $f_1, f_2, \dots, f_q$  pour chacune de ces issues.

Vérifier l'adéquation de ces données à la loi équirépartie sur  $\{a_1, a_2, \dots, a_q\}$  c'est calculer

$$d^2 = \sum_{i=1}^q \left(f_i - \frac{1}{q}\right)^2$$

Sachant que  $D_9$  est le neuvième décile :

- Si  $d^2 \leq D_9$  alors on dira que les données sont compatibles avec le modèle de la loi uniforme au seuil de risque de 10 %.
- Si  $d^2 > D_9$  alors on dira que les données ne sont pas compatibles avec le modèle de la loi uniforme au seuil de risque de 10 %.