

16

LOI DES GRANDS NOMBRES

📌 Résumé

Nous étudions ici la répartition et le comportement d'un échantillon de variables aléatoires. Un résultat majeur est énoncé : la loi faible des grands nombres.

1 Échantillon d'une loi de probabilité

Définition 1

Soit X une variable aléatoire définie sur l'ensemble Ω des issues d'une expérience aléatoire.

Un **échantillon** de taille n de la loi de X est un n -uplet $(X_1; X_2; \dots; X_n)$ de variables aléatoires indépendantes et identiquement distribuées suivant cette loi.

Remarque 2 Une suite x_1, x_2, \dots, x_n de valeurs prises par les X_i est une **réalisation** de cet échantillon.

Exemple 3 On considère X la variable aléatoire qui, à chaque paquet de cartes Pokémon, associe sa valeur une fois ouvert.

On note X_i la variable aléatoire qui, dans un lot de 3 paquets, associe la valeur du i^e paquet.

Les variables X_1 , X_2 et X_3 sont indépendantes et suivent la même loi : celle de X . $(X_1; X_2; X_3)$ est un échantillon de la loi de X de taille 3.

Définitions 4

Soit $(X_1; X_2; \dots; X_n)$ un échantillon de taille n de la loi de X .

► La **variable aléatoire somme** de l'échantillon est la variable aléatoire :

$$S_n = X_1 + X_2 + \dots + X_n.$$

► La **variable aléatoire moyenne** de l'échantillon est la variable aléatoire :

$$\overline{X}_n = \frac{X_1 + X_2 + \dots + X_n}{n}.$$

Exemple 5 Dans l'exemple précédent, $S_3 = X_1 + X_2 + X_3$ est la valeur totale des trois paquets et $\overline{X}_3 = \frac{X_1 + X_2 + X_3}{3}$ est la valeur moyenne du lot.

Propriétés 6 | Indicateurs de S_n

Soit $(X_1; X_2; \dots; X_n)$ un échantillon de taille n de la loi de X .

► $\mathbb{E}[S_n] = n\mathbb{E}[X]$ ► $\text{Var}(S_n) = n\text{Var}(X)$ ► $\sigma(S_n) = \sqrt{n}\sigma(X)$

Démonstration. ► $\mathbb{E}[S_n] = \mathbb{E}[X_1 + \dots + X_n] = \mathbb{E}[X_1] + \dots + \mathbb{E}[X_n] = n\mathbb{E}[X]$ par linéarité de l'espérance.

► $\text{Var}(S_n) = \text{Var}(X_1 + \dots + X_n) = \text{Var}(X_1) + \dots + \text{Var}(X_n) = n\text{Var}(X)$ par indépendance des X_i .

► $\sigma(S_n) = \sqrt{\text{Var}(S_n)} = \sqrt{n}\sqrt{\text{Var}(X)} = \sqrt{n}\sigma(X)$ □

Propriétés 7 | Indicateurs de \overline{X}_n

Soit $(X_1; X_2; \dots; X_n)$ un échantillon de taille n de la loi de X .

► $\mathbb{E}[\overline{X}_n] = \mathbb{E}[X]$ ► $\text{Var}(\overline{X}_n) = \frac{1}{n}\text{Var}(X)$ ► $\sigma(\overline{X}_n) = \frac{1}{\sqrt{n}}\sigma(X)$

Démonstration. $\overline{X}_n = \frac{1}{n}S_n$ donc on utilise les propriétés de l'espérance et de la variance. □

Remarque 8 Plus n est grand, plus $\mathbb{E}[\overline{X}_n]$ est précis pour estimer $\mathbb{E}[X]$.

En effet, la **fluctuation d'échantillonnage** $\text{Var}(\overline{X}_n)$ diminue : $\lim_{n \rightarrow +\infty} \text{Var}(\overline{X}_n) = 0$.

2 Convergence de \overline{X}_n

Théorème 9 | Inégalité de Bienaymé-Tchebychev

Soit X une variable aléatoire.

Pour tout réel $\delta > 0$,

$$\mathbb{P}\left(|X - \mathbb{E}[X]| \geq \delta\right) \leq \frac{\text{Var}(X)}{\delta^2}.$$

Démonstration. Soit $\delta > 0$ fixé. Notons x_1, x_2, \dots, x_n les images possibles de X rangées dans l'ordre strictement croissant. Il existe un ensemble A formé des x_i tels que $|x_i - \mathbb{E}[X]| \geq \delta$.

$$\begin{aligned} \text{Var}(X) &= \sum_{i=1}^n (x_i - \mathbb{E}[X])^2 \times \mathbb{P}(X = x_i) \\ &= \sum_{\substack{i=1 \\ x_i \in A}}^n (x_i - \mathbb{E}[X])^2 \times \mathbb{P}(X = x_i) + \sum_{\substack{i=1 \\ x_i \notin A}}^n (x_i - \mathbb{E}[X])^2 \times \mathbb{P}(X = x_i) \\ &\geq \sum_{\substack{i=1 \\ x_i \in A}}^n (x_i - \mathbb{E}[X])^2 \times \mathbb{P}(X = x_i) \\ &\geq \sum_{\substack{i=1 \\ x_i \in A}}^n \delta^2 \times \mathbb{P}(X = x_i) \\ &\geq \delta^2 \sum_{x_i \in A} \mathbb{P}(X = x_i) \\ &\geq \delta^2 \mathbb{P}\left(|X - \mathbb{E}[X]| \geq \delta\right) \end{aligned}$$

□

Exemple 10 On lance 3 600 fois une pièce de monnaie équilibrée. Soit X la variable aléatoire qui associe le nombre de *Pile* obtenus.

On remarque que $X \sim \mathcal{B}(3600; 0,5)$.

Ainsi, $\mathbb{E}[X] = 3600 \times 0,5 = 1800$ et $\text{Var}(X) = 3600 \times 0,5 \times 0,5 = 900$.

L'inégalité de Bienaymé-Tchebychev donne que, pour tout $\delta > 0$:

$$\mathbb{P}\left(|X - \mathbb{E}[X]| \geq \delta\right) \leq \frac{\text{Var}(X)}{\delta^2} \Leftrightarrow \mathbb{P}\left(|X - 1800| \geq \delta\right) \leq \frac{900}{\delta^2}.$$

Si on souhaite estimer la probabilité que X soit strictement compris entre 1 600 et 2 000, on peut poser $\delta = 200$ et on a :

$$\begin{aligned} \mathbb{P}\left(1600 < X < 2000\right) &= \mathbb{P}\left(1800 - \delta < X < 1800 + \delta\right) \\ &= \mathbb{P}\left(|X - 1800| < \delta\right) \\ &= 1 - \mathbb{P}\left(|X - 1800| \geq \delta\right) \\ &\geq 1 - \frac{900}{\delta^2} \\ &\geq 1 - \frac{900}{200^2} \\ &\geq 0,9775. \end{aligned}$$

Corollaire 11 | Inégalité de concentration

Soit X une variable aléatoire et un échantillon $(X_1; X_2; \dots; X_n)$ de X .

Pour tout réel $\delta > 0$,

$$\mathbb{P}\left(\left|\overline{X}_n - \mathbb{E}[X]\right| \geq \delta\right) \leq \frac{\text{Var}(X)}{n\delta^2}$$

Démonstration. On applique Bienaymé-Tchebychev à \overline{X}_n . □

Exemple 12 On effectue des tirages successifs, avec remise, d'une boule dans une urne contenant deux boules rouges et trois boules noires. On note X la variable aléatoire qui, à un tirage donné, associe 1 si la boule est rouge et 0 sinon.

On considère un échantillon $(X_1; X_2; \dots; X_n)$ de X correspondant à n tirages.

Par construction, $X \sim \mathcal{B}(0,4)$ donc $\mathbb{E}[X] = 0,4$ et $\text{Var}(X) = 0,4 \times 0,6 = 0,24$.

L'inégalité de concentration donne que, pour tout $\delta > 0$:

$$\mathbb{P}\left(\left|\overline{X}_n - \mathbb{E}[X]\right| \geq \delta\right) \leq \frac{\text{Var}(X)}{n\delta^2} \Leftrightarrow \mathbb{P}\left(\left|\overline{X}_n - 0,4\right| \geq \delta\right) \leq \frac{0,24}{n\delta^2}.$$

Nous souhaitons maintenant déterminer à partir de combien de tirages, l'indicateur \overline{X}_n est compris, avec une probabilité supérieure ou égale à 0,95, entre 0,35 et 0,45.

$$\begin{aligned} \mathbb{P}\left(0,35 < \overline{X}_n < 0,45\right) &= \mathbb{P}\left(\left|\overline{X}_n - 0,4\right| < 0,05\right) \\ &= 1 - \mathbb{P}\left(\left|\overline{X}_n - 0,4\right| \geq 0,05\right) \\ &\geq 1 - \frac{0,24}{n \times 0,05^2}. \end{aligned}$$

Donc, pour que $\mathbb{P}(0,35 < \overline{X}_n < 0,45) \geq 0,95$, regardons n tel que :

$$\begin{aligned} 1 - \frac{0,32}{n \times 0,05^2} &\geq 0,95 \\ \Leftrightarrow 0,05 &\geq \frac{0,32}{n \times 0,05^2} \\ \Leftrightarrow n &\geq \frac{0,32}{0,05^3} \\ \Leftrightarrow n &\geq 2650. \end{aligned}$$

Théorème 13 | Loi des grands nombres

Soit X une variable aléatoire et un échantillon $(X_1; X_2; \dots; X_n)$ de X .

Pour tout $\epsilon > 0$ fixé,

$$\lim_{n \rightarrow +\infty} \mathbb{P}\left(\left|\overline{X}_n - \mathbb{E}[X]\right| \geq \epsilon\right) = 0.$$

Démonstration. On applique l'inégalité de concentration à \overline{X}_n :

$$0 \leq \mathbb{P}\left(\left|\overline{X}_n - \mathbb{E}[X]\right| \geq \delta\right) \leq \frac{\text{Var}(X)}{n\epsilon^2}.$$

On conclut par le théorème des gendarmes. □

Remarque 14 On dira que la suite de variables aléatoires (\overline{X}_n) converge en probabilité vers $\mathbb{E}[X]$.