

## Projet: simulation d'une variable aléatoire

**Remarques.** a) Ce projet est facultatif et peut être fait avec le logiciel **R** ou le langage **C**. Il est noté sur 20 et n'est en aucun cas pénalisant par rapport à la note de Devoir Surveillé (DS) puisqu'on comptera le  $\max(\text{Note Projet}, \text{Note DS})$ . b) Il est fortement recommandé que ce soit fait en binôme même s'il est autorisé de le faire seul. Il peut aussi être fait en groupe de  $n$  étudiants,  $n \geq 3$ . Dans ce cas il sera noté sur  $20 - n$ . Si deux copies rendues séparément présentent des ressemblances la note finale des deux groupes sera de

$$\min(\text{NFG1}, \text{NFG2}) - S$$

où **NFG1** et **NFG2** sont les notes finales des deux groupes et  $S$  une note comprise entre 1 et 20 qui dépend du (et augmente avec le) degré de similitude des deux copies.

ENONCÉ. On se donne une variable aléatoire  $X$  à valeurs dans  $\{-2, -1, 0, 1\}$  avec

$$\mathbb{P}(X = -2) = \frac{1}{4}, \quad \mathbb{P}(X = -1) = \frac{1}{6}, \quad \mathbb{P}(X = 0) = \frac{1}{3}, \quad \mathbb{P}(X = 1) = \frac{1}{4}.$$

↪ **Simulation de réalisations de  $X$ .** L'objectif de cette partie est de simuler  $n$  réalisations indépendantes  $X_1(\omega), \dots, X_n(\omega)$  (autrement dit, une suite de  $n$  valeurs de  $X(\omega)$  prises indépendamment les unes des autres, on l'appelle aussi un échantillon de taille  $n$  de la loi de la variable aléatoire  $X$ ) de la variable aléatoire  $X$  en utilisant le langage **C** ou le logiciel **R**, où le nombre de simulations  $n$  sera fixé. Par exemple, si `SimulLoiDiscrete(n, ...)` est la fonction **C** qui simule  $n$  réalisations indépendantes de la variable aléatoire  $X$ , l'appelle à la fonction `SimulLoiDiscrete(10, ...)` générera de façon aléatoire 10 valeurs appartenant à l'ensemble  $\{-2, -1, 0, 1\}$  des valeurs prises par la variable aléatoire  $X$ . On peut par exemple avoir la suite de valeurs

$$-1 \quad 0 \quad 0 \quad -2 \quad -2 \quad 0 \quad 1 \quad -1 \quad 0 \quad 1.$$

La simulation d'une variable aléatoire est basée sur le principe suivant. Soit  $X$  une variable aléatoire de fonction de répartition  $F(x) = \mathbb{P}(X \leq x)$ ,  $x \in \mathbb{R}$ . On suppose que l'on sait simuler des réalisations d'une variable aléatoire  $U$  de loi uniforme sur  $]0, 1[$ :  $U \sim \mathcal{U}(]0, 1[)$ . Pour simuler des réalisations de la variable aléatoire  $X$  on utilise le résultat suivant: si  $F^{-1}$  est la fonction quantile de  $X$  définie par

$$F^{-1}(u) := \inf\{x \in \mathbb{R} : F(x) \geq u\}, \quad \text{pour tout } u \in ]0, 1[$$

alors  $X$  et  $F^{-1}(U)$  ont la même loi de probabilité: on note  $X \stackrel{\mathcal{L}}{=} F^{-1}(U)$ . Nous allons utiliser ce dernier résultat pour simuler des réalisations de  $X$ .

Posons  $p_1 = \frac{1}{4}$ ,  $p_2 = \frac{1}{6}$ ,  $p_3 = \frac{1}{3}$  et  $p_4 = \frac{1}{4}$  les probabilités que  $X$  prenne les valeurs  $a_1 = -2$ ,  $a_2 = -1$ ,  $a_3 = 0$ ,  $a_4 = 1$ , respectivement. La fonction de répartition  $F$  de  $X$  est

$$F(x) = \begin{cases} 0 & \text{si } x < -2 \\ 1/4 & \text{si } x \in [-2, -1[ \\ 5/12 & \text{si } x \in [-1, 0[ \\ 9/12 & \text{si } x \in [0, 1[ \\ 1 & \text{si } x \geq 1 \end{cases}$$

et la fonction quantile  $F^{-1}$  est donnée par

$$F^{-1}(u) = \begin{cases} a_1 & \text{si } u \in ]0, 1/4] \\ a_2 & \text{si } u \in ]1/4, 5/12] \\ a_3 & \text{si } u \in ]5/12, 9/12] \\ a_4 & \text{si } u \in ]9/12, 1[. \end{cases}$$

Ainsi, pour simuler une réalisation  $x$  de  $X$  on procède comme suit:

- **on simule d'abord une réalisation  $u$  de la loi uniforme sur  $]0, 1[$ .**
- **Si  $u \in ]0, 1/4]$  alors on pose  $x = a_1$ , si  $u \in ]1/4, 5/12]$  alors on pose  $x = a_2$ , si  $u \in ]5/12, 9/12]$  alors on pose  $x = a_3$  et enfin, si  $u \in ]9/12, 1[$  alors on pose  $x = a_4$ .**

On répètera cette dernière action  $n$  fois si on veut simuler un échantillon de taille  $n$  de  $X$ .

↪ *Indications.* Vous pouvez utiliser "l'entête" ci-dessous (à compléter éventuellement) pour votre programme C.

```
#define n 10
#define p1 1.0/4
#define p2 1.0/6
#define p3 1.0/3
#define p4 1.0/4

#define a1 -2
#define a2 -1
#define a3 0
#define a4 1

#include<stdio.h>
#include<math.h>
#include<stdlib.h>
#include<time.h>
#include <ctype.h>
#include<string.h>
```

1. Ecrivez une fonction *SimulLoiDiscrete* telle que l'appelle à la fonction

$$\text{SimulLoiDiscrete}(n, a, a2, a3, a4, p1, p2, p3, p4, p5, \text{ValSim})$$

ne renvoie rien mais remplit le tableau *ValSim* des  $N$  valeurs simulées de la variable aléatoire  $X$ . Le prototype de la fonction ressemblera a

$$\text{void SimulLoiDiscrete}(\text{int } n, \dots, \text{double } * \text{Valsim})$$

2. Appelez la fonction *SimulLoiDiscrete*( $n, \dots$ ) pour  $n = 10^3$ ,  $n = 10^4$ ,  $n = 10^5$  et pour chaque valeur de  $n$  comparer les fréquences d'apparition de chacune des valeurs du tableau *ValSim* et les comparer aux probabilités  $p_i$ ,  $i = 1, 2, 3, 4$ . Commenter.
3. Représentez graphiquement les fréquences d'apparition de chacune des valeurs du tableau *ValSim* en fonction de  $n$ , pour  $n = 1, 2, 3, 4, \dots, 1000$ . Pour cela, vous pourriez récupérer le tableau des fréquences dans un fichier texte et faire le graphique avec un logiciel de votre choix.

*Autres indications.* Le tableau *ValSim* dans la fonction *main* pourra être défini comme suit

$$\text{ValSim} = (\text{double } *) \text{malloc}(n * \text{sizeof}(\text{double}));$$

Dans la fonction *main*, on doit rajouter l'instruction ci-après avant d'appeler la fonction *SimulLoiDiscrete*:

$$\text{srand}((\text{unsigned})\text{time}(\text{NULL}));$$

Pour simuler une réalisation de la loi uniforme dans la fonction *SimulLoiDiscrete* utilisez l'instruction  $u = \text{rand}() / (\text{RAND\_MAX} + 1.0)$ ;

↪ **Approximation de  $\mathbb{E}(X)$  par la loi des grands nombres.** La loi des grands nombres s'énonce comme suit: si  $X_1, \dots, X_n$  est une suite de  $N$  réalisations indépendantes de  $X$  alors, avec probabilité 1, la moyenne empirique  $\bar{X}_n = (X_1 + \dots + X_n) / n$  converge vers  $\mathbb{E}(X)$  lorsque  $N$  tend vers l'infini.

4. Calculer  $\mathbb{E}(X)$ , puis (en posant  $f_n(i)$  la fréquence d'apparition de  $i$ ,  $i \in \{-2, -1, 0, 1\}$ )

$$\bar{X}_n(\omega) = \frac{X_1(\omega) + \dots + X_n(\omega)}{n} = (-2) \times f_n(-1) + (-1) \times f_n(-1) + 0 \times f_n(0) + 1 \times f_n(1) \quad (1)$$

en utilisant les fréquences obtenues dans la question 2. pour  $n = 10^3$ ,  $n = 10^4$  et  $n = 10^5$ . Comparez ces valeurs de  $\bar{X}_n(\omega)$  à  $\mathbb{E}(X)$ .

5. Représentez sur le même graphique la constante  $\mathbb{E}(X)$  et la fonction  $n \mapsto \bar{X}_n$ , pour  $n = 1, 2, 3, 4, \dots, 1000$ . Pour cela, vous pourriez récupérer le tableau (pour  $n$  variant) des moyennes empiriques  $\bar{X}_n$  dans un fichier texte et faire le graphique avec un logiciel de votre choix.

↪ **Théorème de la limite centrale.** Le théorème central limite s'énonce comme suit: soit  $X_1, \dots, X_n$  est une suite de  $n$  réalisations indépendantes de  $X$ , si la  $\text{Var}(X) = \sigma^2$  est finie alors la variable aléatoire

$$Z_n = \frac{\bar{X}_n - \mathbb{E}(X)}{\sqrt{\text{Var}(\bar{X}_n)}} = \sqrt{n} \frac{\bar{X}_n - \mathbb{E}(X)}{\sigma} \quad (2)$$

converge (en loi) vers une variable aléatoire Normale centrée réduite  $Z \sim \mathcal{N}(0, 1)$ , lorsque  $n \rightarrow +\infty$ .

Maintenant, on sait que pour  $n$  fixé, une réalisation  $Z_n(\omega^1) = Z_n^1$  de la variable aléatoire  $Z_n$  est obtenue en simulant un échantillon de taille  $n$  de la loi de  $X$  et en calculant la quantité (2). On pose  $n_1 = 20$  et  $n_2 = 30$ .

6. Simulez un échantillon  $Z_n(\omega^1) = Z_n^1, \dots, Z_n(\omega^m) = Z_n^m$  de taille  $m = 3$  de la loi de  $Z_n$ , pour  $n = n_1$ , puis pour  $n = n_2$ . Pour cela, vous devez calculer explicitement  $\text{Var}(X)$ .
7. Simulez un échantillon  $Z_n(\omega^1) = Z_n^1, \dots, Z_n(\omega^m) = Z_n^m$  de taille  $m = 5 \times 10^5$  de la loi de  $Z_n$ , pour  $n = n_1$ , puis pour  $n = n_2$ . Récupérez les résultats (pour  $n_1 = 20$  et pour  $n_2 = 30$ ) obtenus dans deux fichiers textes séparés.
8. En utilisant le logiciel de votre choix, tracez, dans deux figures séparées, l'histogramme des fréquences pour l'échantillon  $Z_n^1, \dots, Z_n^m$  (on pourra choisir 30 classes). Dans chacune des deux figures précédentes, tracez la densité  $f$  de la loi Normale centrée réduite définie par

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2}, \quad x \in \mathbb{R}.$$

9. Commentez les graphiques de la question 8 en vertu du théorème central limite.

**Remarque.** Pour ceux qui souhaitent le faire avec le logiciel **R** vous trouverez dans la page de M. Chiquet

<http://julien.cremierfamily.info/index.html> une introduction à **R**.