

# TP 1 : Simulation, visualisation de données avec R

Ce TP n°1 a pour but la maîtrise des outils classiques de simulation probabiliste et de représentation de données.

**Exercice 0 : Reprise en main de la console : calculs rapides** Recopier dans la console chacun de ces calculs, puis l'exécuter (en appuyant sur Entrée). Assurez-vous de bien comprendre le résultat renvoyé par R.

```
3+1.2, 2-7.8, 2/5, 2*5.5, sqrt(100), log(2), exp(1), log(exp(3)), log10(10000), sin(pi/2), cos(pi)
```

La commande ? devant une fonction permet d'obtenir de l'aide. Par exemple, pour demander de l'aide sur la fonction `exp` on écrira:

```
?exp
```

R permet aussi de définir des tableaux à l'aide de `c(...)`. Définir un tableau `tab` contenant 6 nombres réels de votre choix. Ensuite, que renvoient les commandes suivantes ?

```
tab[2], tab[-2], tab[2:5], tab[c(2,5)], tab+0.5, tab/2, tab*5, exp(tab)
```

Pour la suite du TP, y a quatre commandes simples à retenir avec R pour chaque loi usuelle : `rmaloi` permet de simuler des variables selon maloi, `dmaloi` calcule la densité de maloi, `pmaloi` pour la fonction de répartition, et `qmaloi` pour les quantiles de maloi.

## Exercice 1 : Loi normale, commandes classiques pour les lois continues

1. Simulez une réalisation d'un échantillon de  $n = 100$  variables indépendantes et de même loi normale de moyenne  $\mu = -2$  et de variance 9. On utilisera donc la fonction `rnorm` qui prend en paramètres  $n$ , `mean` (la moyenne) et `sd` (l'écart-type).

Calculer la moyenne et la variance de la réalisation.

Afficher la représentation de la réalisation sous la forme d'une boîte à moustaches (fonction `boxplot`)

2. Tracer l'histogramme du jeu de données ainsi obtenu (fonction `hist` avec option `freq=F`), et réfléchir à comment régler le paramètre `breaks`. Puis à l'aide de la fonction `curve` (avec option `add=T, col="red"`), superposer à l'histogramme la densité théorique de la loi en question.

3. Répéter les deux premières questions avec  $n = 1000$  puis  $n = 10000$ . Qu'observe-t-on?

4. Pour une réalisation  $(x_1, \dots, x_n)$  d'un échantillon, la fonction de répartition empirique  $F_{emp}$  est définie par

$$\forall y \in \mathbb{R}, F_{emp}(y) = \frac{1}{n} \# \{1 \leq i \leq n, x_i \leq y\}.$$

A l'aide des fonctions `plot` et `ecdf`, représenter la fonction de répartition empirique de la réalisation. Superposer au graphique la fonction de répartition (théorique) de la loi normale étudiée. Qu'observe-t-on ?

**Exercice 2 : Lançons des fléchettes !** On dispose d'un carré de côté 2. On place l'origine  $O$  du repère au centre du carré  $[-1, 1] \times [-1, 1]$ . On considère tout d'abord l'expérience aléatoire suivante : on lance au hasard des fléchettes dans le carré, avec une abscisse et une ordonnée indépendantes et toutes deux de loi uniforme sur  $[-1, 1]$ .

1. Simuler  $n = 100$  lancers indépendants de fléchettes. Les représenter graphiquement sur le carré qui sert de cible.

2. On repère la qualité d'un lancer à la distance  $D$  de la flèche au centre de la cible. Tracer l'histogramme des réalisations de  $D$ .

Quelle est la moyenne de la réalisation ? Et la moyenne théorique (espérance) de  $D$  ?

3. Refaire l'histogramme de  $D$  pour  $n = 10^7$ . (Indication : là encore, attention à bien calibrer **breaks**).

Quelle semble être la loi de  $D$  sachant  $D \leq 1$  ? Interprétez.

4. Proposez deux méthodes pour estimer  $\mathbb{P}(D \leq 1)$ : l'une à l'aide de simulations, l'autre à l'aide d'un calcul.

5. Maintenant arrive un autre lanceur de fléchettes qui semble bien plus aguerri, et que l'abscisse  $x$  et l'ordonnée  $y$  du lancer sont deux variables indépendantes, gaussiennes centrées de variance  $1/2$ . Calculer la moyenne et représenter l'histogramme de réalisations indépendantes de  $D$  sous ce nouveau modèle. Commentez.

Selon vous, ce joueur est-il vraiment meilleur ?

**Exercice 3 : Promenons-nous sur  $\mathbb{Z}$ ...** Un promeneur habite dans un monde à une seule dimension. Il décide d'aller se balader pour prendre l'air entre deux confinements. On suppose que ces déplacements ne peuvent se faire que sur l'axe des entiers relatifs ( $\mathbb{Z}$ ) et on les modélise comme suit: Au temps  $t = 0$ , il est chez lui, au point 0, et à chaque pas de temps, il se déplace indépendamment vers la droite (de  $+1$  donc) avec une probabilité  $p$ , ou bien vers la gauche (de  $-1$ ) avec une probabilité  $q = 1 - p$ . La donnée successive de sa position en fonction du temps est appelée une marche aléatoire.

Une façon simple de simuler une telle marche aléatoire du temps  $t = 0$  au temps  $t = T$  est la suivante : il suffit de simuler un vecteur de taille  $T$  de variables  $X_1, \dots, X_T$  indépendantes et de même loi, satisfaisant

$$\mathbb{P}(X_1 = -1) = 1 - p, \quad \mathbb{P}(X_1 = +1) = p.$$

Ensuite, il suffit de réaliser que la position de notre promeneur au temps  $t$ , notée  $S_t$ , est donnée par

$$S_t := \sum_{s=1}^t X_s.$$

1. Simuler à l'aide de R une marche aléatoire de taille  $T = 30$ , avec  $p = 0.65$ . Stocker cette marche dans un vecteur *marche*. (Indication : pour simuler les  $X_i$  on pourra utiliser des variables i.i.d. de loi uniformes sur  $[0,1]$ , puis regarder si elles sont inférieures à  $p$ ...) )

2. Refaire une simulation pour  $T = 200$ , et représenter graphiquement la marche aléatoire  $S_t$  en fonction du temps  $t$ : faites cela plusieurs fois. Le promeneur rentrera-t-il chez lui un jour ? Interprétez.

3. Quelle valeur de  $p$  semble être la plus judicieuse pour espérer rentrer que le promeneur rentre un jour chez lui ? Refaire plusieurs simulations avec la nouvelle valeur de  $p$ , pour  $T = 2000$ , et représenter graphiquement la marche aléatoire  $S_t$  en fonction du temps  $t$ . Qu'observe-t-on cette fois-ci ? Interprétez.

Dans toute la suite on prend  $p = 1/2$ . On s'intéresse au premier temps  $T_0$  de retour en 0, c'est-à-dire au premier instant où le promeneur revient chez lui. Mathématiquement,

$$T_0 := \inf \{n \in \mathbb{N}^*, S_n = 0\},$$

avec la convention  $T_0 = \infty$  si  $\forall n \in \mathbb{N}^*, S_n \neq 0$ . On peut en fait montrer que presque sûrement  $T_0 < \infty$ .

4. Compléter le code ci-dessous, qui définit la fonction `T0()` (sans argument) qui simule et renvoie le temps de retour en 0 pour une marche du promeneur de paramètre  $p = 1/2$ .

```
T0 <- function(){
t = 0
position = 0
while (F) {# <-- A compléter
# t= <-- A compléter
position <- position + 2*(runif(1)<0.5)-1}
t
}
```

5. A l'aide de la fonction `T0`, simuler  $m = 1000$  valeurs de  $T_0$ . Calculer son espérance (empirique), sa variance (empirique). Représenter son histogramme. A votre avis, que vaut l'espérance (théorique) de  $T_0$  ?