

## TD 1 Notions statistiques

### Exercices sur l'utilisation de R

Voir "*Introduction au logiciel R*" par S. Déjean

[http://www.math.univ-toulouse.fr/~sdejean/PDF/semin-R\\_juin\\_2014.pdf](http://www.math.univ-toulouse.fr/~sdejean/PDF/semin-R_juin_2014.pdf)

Trois commandes très utiles pour les exercices :

1) La boucle "for" dont le syntaxe est le suivant :

```
for (compteur in vecteur) {  
liste d'instructions à exécuter  
}
```

Exemple : pour calculer la somme et le produit de 10 premiers entier :

```
p=1;s=0  
for (i in 1 :10){s=s+i; p=p*i}  
on obtient donc s=0+...10 et p=10!
```

2) La boucle "while" dont le syntaxe est le suivant :

```
while (condition) {  
liste d'instructions à exécuter  
}
```

Exemple : pour trouver une approximation du nombre pi avec le dénominateur 113 :

```

k=1
while (k/113 < pi) { k=k+1}

print (k/113)

```

3) Echantillonnage "**sample**" dont le syntaxe est le suivant :

`sample(vecteur, n, replace = TRUE)` # population :  $1 : N \leftrightarrow N$   
fournit  $n$  valeurs prises au hasard avec remise dans le vecteur donné,  
représentant une réalisation  $(x_1 \dots, x_n)$  d'un échantillon de taille  $n$   
 $(X_1 \dots, X_n)$ .

Exemple 1 : On prélève d'un échantillon de taille 8 (avec remise)  $(X_1 \dots X_8)$   
dans la population constituant de  $\{1, 2, 3\}$  On peut générer 15 réali-  
sations de l'échantillon  $(X_1 \dots X_8)$  plus 15 réalisations de la moyenne  
d'échantillon  $X_{\text{bar}} = \text{sum}(X_i)/n$  qui est un variable aléatoire :

**Population=1 :3**

**N=12 ; n=8**

**Echantillon=matrix(NA, nrow=N, ncol=n)** # N réalisations

**Moyenne.echantillon=rep(NA,N)** ; # N réalisations

**for (j in 1 :N) {**

**Echantillon[j,]=sample(Population, n, replace=T)**

**Moyenne.echantillon[j]=mean(Echantillon[j,]) }**

Echantillon

Moyenne.echantillon

**Exercice 1 :**

a) Dans un bassin où vivent  $N = 10$  poissons  $P_1, \dots, P_N$ . Si on en  
pêche (simultanément) 3, quels sont les possibilités ? Que signifie **choi-**  
**sir** (simultanément)  $k = 3$  poisson **au hasard** ?

$L=1 :10 ; \text{combn}(L, 3)$

b) On suppose que les poissons sont tous identiques et qu'il y a  $K = 4$  poissons marqués parmi les 10. Quelle est la probabilité quand on en pêche (simultanément)  $k = 3$  d'en trouver  $i=2$  qui sont marqués? Quelle est la loi de probabilité?

On Simule  $M = 500$  réalisations d'une variable aléatoire suivant une loi hypergéométrique  $H(10, 4, 3)$  dans la suite.

$$\text{hyper}(K, N-K, k)$$

c) Déterminer les fréquences d'obtenir  $i = 0, \dots, 3$  poissons marqués parmi 4, comparer avec les effectifs théoriques.

d) Tracer un diagramme à bâtons à barres accolées des effectifs observés et des effectifs théoriques.

e) Comparer la moyenne théorique avec la moyenne observée de ces  $M$  réalisations.

f) Mêmes questions pour  $N = 40, K = 10$  et  $k = 9$ .

## Exercice 2 :

a) On lance un dé équilibré et on définit une v.a.  $X = 0$  si le résultat du dé est inférieur ou égal à 4,  $X = 1$  sinon.

On note  $S$  le nombre de 1 après  $n = 5$  lancers. Quelle est la loi de  $S$ ?

b) Simuler  $M = 1000$  réalisations de la v.a.  $S$ , déterminer les fréquences d'avoir  $S = 0, \dots, 5$ . Comparer avec les effectifs théoriques.

c) Tracer un diagramme à bâtons à barres accolées des effectifs observés et des effectifs théoriques.

d) Comparer la moyenne théorique avec la moyenne observée de ces  $M$  réalisations.

e) Quelle est la différence entre l'exercice actuel et le précédent?

**Exercice 3 :** On s'intéresse à la largeur des anneaux de croissance des arbres. On prend le fichier "treering" dans la librairie "datasets" avec 7980 comme étant le cardinal de la population. On note  $\mu$  la moyenne (théorique) de largeurs et on souhaite avoir une idée sur la grandeur du paramètre  $\mu$ . Pour ce faire, on va construire  $M = 500$  réalisations, basé sur un échantillon de taille  $n = 65$ .

- a) Sauvegarder ces 7980 valeurs dans un vecteur nommé **Population**, étudier ses caractéristiques en utilisant la commande "summary".
- b) Générer  $M = 500$  réalisations de l'échantillon  $(X_1, \dots, X_n)$  de taille  $n = 65$ , sauvegarder 500 réalisations de l'échantillon ainsi que sa moyenne.
- c) Comparer la moyenne théorique, la moyenne d'échantillon ainsi que la moyenne des moyennes observées. Quelle est la différence entre la nature des trois moyennes ?

**Exercice 4 :**

On continue à lancer un dé équilibré. On définit une v.a.  $Y$  le nombre de lancers nécessaire pour obtenir un résultat supérieur ou égal à 5 pour la première fois.

- a) Déterminer la loi de  $Y$ .
- b) Simuler  $M = 1000$  réalisations de la v.a.  $Y$ , déterminer les fréquences d'avoir  $Y = 1, \dots, 14$ , puis  $Y \geq 15$ . Comparer avec les effectifs théoriques.
- c) Tracer un diagramme à bâtons à barres accolées des effectifs observés et des effectifs théoriques.

d) Comparer la moyenne théorique avec la moyenne observée de ces  $M$  réalisations.

### Exercice 5 :

Si  $U$  est une v.a. de loi uniforme  $U(0, 1)$ , alors  $Y = -\frac{\log(U)}{\lambda}$  suit une loi d'exponentielle de paramètre  $\lambda$ . On pose  $\lambda = 1/2$  dans la suite. On simule  $M = 5000$  réalisations de la v.a.  $U$  de loi uniforme  $U(0, 1)$ , par la transformation on en obtient ainsi 1000 réalisations d'une v.a. d'une loi d'exponentielle de paramètre  $\lambda$ . on note le vecteur obtenu par  $x$ .

a) Tracer l'histogramme de ces  $M$  réalisations en utilisant

```
(m=floor(min(x))); (M=ceiling(max(x))); brk=c(seq(m,M,0.3));
```

```
hist(x, probability = TRUE, col = "light blue",breaks=brk)
```

b) On superpose le graphique de la densité théorique  $\exp(1/2)$ , indépendant des données, sur le graphique précédent

```
u=seq(0,15,length=300);v=dexp(t,rate=1/2)
```

```
lines(u,v, type="l", ,col="red",lwd = 2,add=T)
```

c) On peut calculer la proportion des données comprises entre 8 et 12 :  
 $(\text{length}(x[(x \geq 8) \& (x \leq 12)])) / M$

d) aussi la probabilité  $P(8 \leq X \leq 12) = F(12) - F(8)$

où la fonction de répartition de la loi est donnée par "pexp(t, rate=1/2)" en utilisant la fonction de répartition

```
pexp(12,rate=1/2)-pexp(8,rate=1/2)
```

```
f=function(x)exp(-x/2)/2; integrate(f, 8, 12);
```

e) Son graphique

```
x=seq(0.5,1.4,length=300); y=dexp(x,rate=1/2 )
```

```
plot(x,y,type="l", lwd=2, col="red")

x=seq(8,12,length=200) ; y=dexp(x,rate=1/2)

polygon(c(8,x,12),c(0,y,0),col="gray")
```

### Exercice 6 :

- a) On simule  $M = 5000$  réalisations d'une v.a. de loi  $N(-10, 1.5^2)$ , noté  $x_n$ .
- b) On affiche l'ensemble de  $x_n$  tels que  $-12 < x_n \leq -10$ .
- c) On compare la proportion de  $x_n$  tels que  $-12 < x_n \leq -10$  avec leur probabilité.
- d) On superpose la fonction de densité de  $X$  avec l'histogramme.

### Exercice 7 : Triangle aléatoire

On fixe trois points  $A_1 = (1, 1)$ ,  $A_2 = (50, 50 * \text{sqrt}(3))$  et  $A_3 = (100, 1)$ .

- a) On choisit au hasard un point  $P_1 = (x_1, y_1)$  dont les deux composantes sont prises au hasard dans le carré de sommets  $(1,1)$ ,  $(100,1)$ ,  $(100,100)$  et  $(1,100)$ .
- b) On sélectionne un des 3 points  $A_i$  avec probabilité  $1/3$ . Si  $A_i$  est choisi, le prochain point  $P_{i+1}$  se trouvera au mi-chemin entre le point actuel et le point  $P_i$ , ainsi de suite,  $i = 2, \dots, N = 5000$ .
- c) Tracer le graphique de ces 50000 points ainsi obtenus. Que constatez-vous ?