



INITIATION AU LOGICIEL R - TP 1

Commandes et fonctions de bases, manipulation de vecteurs et matrices

Exercice 1 : Anticiper ce que font les 6 instructions suivantes, puis vérifier vos réponses en les saisissant dans la console.

1. `1:3^2`
2. `(1:5)*2`
3. `x<-2` et `2x<-2*x`
4. `x<-1` et `x<-1`
5. `var<-3` et `Var*2`
6. `TRUE+T+FALSE*F+T*FALSE+F`

Exercice 2 : Vecteurs

1. Créer les 3 vecteurs ci-dessous à l'aide de la fonction `rep`. Vous les nommerez respectivement `vec1`, `vec2` et `vec3`.
`(1, 2, 3, 4, 5, 1, 2, 3, 4, 5, 1, 2, 3, 4, 5)`
`(1, 1, 1, 2, 2, 2, 3, 3, 3, 4, 4, 4, 5, 5, 5)`
`(1, 1, 2, 2, 2, 3, 3, 3, 3, 4, 4, 4, 4, 4)`
2. Créer le vecteur `vec4` ci-dessous avec la fonction `paste` :
`"A1)" "A2)" "A3)" "A4)" "A5)" "A6)" "A7)" "A8)" "A9)" "A10)"`
3. Le vecteur `letters` contient les 26 lettres de l'alphabet. A l'aide d'une instruction R, déterminer la coordonnée de la lettre `q` dans l'alphabet.
4. Donner une instruction permettant de remplacer les valeurs manquantes d'un vecteur `x` quelconque par des zéros.
5. Donner une instruction permettant de remplacer les éléments à valeur négative d'un vecteur de nombres `y` par leur opposé.
6. Soit `x` un vecteur de nombres. Que font les instructions `which.min(x)` et `which(x==min(x))` ?

Exercice 3 : Quelques calculs

1. Programmer la somme suivante en une ligne de code : $\sum_{i=10}^{100} (i^3 + 4i^2)$.
2. Soient $\mathbf{x} = (x_1, x_2, \dots, x_n)$ et $\mathbf{y} = (y_1, y_2, \dots, y_n)$ deux vecteurs de taille n (prendre par exemple `x=sample(0:99,100,replace=TRUE)` et `y=sample(0:99,100,replace=TRUE)`.)
 - (a) Créer le vecteur $(y_2 - x_1, \dots, y_n - x_{n-1})$.
 - (b) Créer le vecteur $\left(\frac{\sin(y_1)}{\cos(x_2)}, \frac{\sin(y_2)}{\cos(x_3)}, \dots, \frac{\sin(y_{n-1})}{\cos(x_n)} \right)$.
 - (c) Créer le vecteur $(x_1 + 2x_2 - x_3, x_2 + 2x_3 - x_4, \dots, x_{n-2} + 2x_{n-1} - x_n)$.

(d) Calculer $\sum_{i=1}^{n-1} \frac{e^{-x_{i+1}}}{x_i + 10}$.

Exercice 4 : Valeurs manquantes

1. Fixer la graine du générateur de nombres aléatoires (**set.seed**) à la valeur 7 et créer un vecteur **vec1** de 100 nombres tirés uniformément entre 0 et 7 (**runif**). Calculer la moyenne empirique (**mean**) et la variance empirique des valeurs contenues dans **vec1**.

Rappel : Soit $\mathbf{x} = (x_i)_{1 \leq i \leq n}$ un vecteur et \bar{x} la moyenne empirique de ses composantes. La variance empirique des x_i est donnée par :

$$\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2.$$

2. Créer une copie du vecteur **vec1** nommée **vec2**. Fixer la graine du générateur de nombres aléatoires à la valeur 8. Sélectionner 10 indices au hasard parmi les 100 indices des composantes du vecteur **vec2** (**sample**). Remplacer la valeur des composantes correspondant à ces indices par NA (valeur manquante).
3. Calculer les moyenne et variance empiriques des éléments du vecteur **vec2** : directement (sans gestion des NA) puis en utilisant l'argument **na.rm=TRUE** (en gérant les NA).
4. Créer un vecteur **vec3** en supprimant les composantes de **vec2** qui contiennent une valeur manquante et calculer les moyenne et variance empiriques des composantes de ce vecteur **vec3**. Commenter l'action de **na.rm=TRUE**.
5. Créer une copie du vecteur **vec2** nommée **vec4**. Remplacer les valeurs manquantes de **vec4** par la moyenne empirique des composantes du vecteur **vec3**.
6. Créer une copie du vecteur **vec2** nommée **vec5**. Remplacer les valeurs manquantes de **vec5** par un tirage aléatoire avec remise parmi les valeurs non manquantes du vecteur **vec2** (**sample**).

Exercice 5 : Création et inversion de matrice, sélection dans une matrice

1. Créer la matrice **mat** suivante avec les noms de lignes et de colonnes :

	colonne 1	colonne 2	colonne 3	colonne 4
ligne-1	1	5	5	0
ligne-2	0	5	6	1
ligne-3	3	0	3	3
ligne-4	4	4	4	2

2. Créer un vecteur contenant les éléments diagonaux de la matrice **mat**.
3. Créer une matrice contenant uniquement les deux premières lignes de la matrice **mat**.
4. Créer une matrice contenant uniquement les deux dernières colonnes de la matrice **mat**.
5. Créer une matrice contenant toutes les colonnes de la matrice **mat** sauf la troisième.
6. Calculer le déterminant puis inverser la matrice **mat** en utilisant les fonctions appropriées. Vérifier par un calcul approprié que la matrice obtenue est bien l'inverse de **mat**.
7. Créer un vecteur dont les éléments sont obtenus en sommant ligne par ligne les éléments de **mat** (utiliser **apply**).
8. Créer un vecteur dont les éléments sont obtenus en prenant le plus grand élément de chaque colonne (utiliser **apply**).
9. Créer une matrice contenant les colonnes de la matrice **mat** dont tous les éléments sont plus petits que 6 (utiliser **apply** et **all** pour sélectionner ces colonnes).
10. Créer une matrice contenant les lignes de la matrice **mat** qui ne présentent aucun zéro.

Exercice 6 : Calcul matriciel et modèle de régression linéaire

On considère le jeu de données **mtcars** disponible sous R. Ce jeu de données contient les mesures de 11 variables qui décrivent les performances de 32 voitures (modèles 1973-1974). Soumettre successivement les commandes **data(mtcars)**, **dim(mtcars)**, **head(mtcars)** et **help(mtcars)**. Commenter les sorties. On considère le modèle :

$$\text{mpg} = \beta_0 + \beta_1 \text{hp} + \beta_2 \text{wt} + \varepsilon,$$

où `mpg` désigne le vecteur contenant la consommation de carburant des 32 véhicules (en gallons par miles), `hp` le vecteur contenant leur puissance (en nombre de chevaux) et `wt` le vecteur contenant leur poids (en milliers de livres). ε est un vecteur d'erreurs dont les termes sont indépendants et identiquement distribués suivant une loi normale $\mathcal{N}(0, \sigma^2)$. On cherche à estimer les paramètres β_0 , β_1 et β_2 par la méthode des moindres carrés ordinaires (MCO).

1. A partir de `mtcars`, créer le vecteur `y` contenant les valeurs de consommation de carburant (`mpg`).
2. Créer une matrice `X` qui aura autant de lignes que `y` et 3 colonnes. La première colonne ne contiendra que des 1, la seconde contiendra le vecteur `hp` et la troisième le vecteur `wt` (on pourra utiliser la fonction `cbind`).
3. Calculer la transposée \mathbf{X}^T de `X`.
4. Calculer de deux façons différentes le produit matriciel $\mathbf{X}^T \mathbf{X}$ (pour l'une, on utilisera la fonction `crossprod`).
5. Calculer l'inverse $(\mathbf{X}^T \mathbf{X})^{-1}$ de ce produit matriciel.
6. Calculer le produit matriciel $\mathbf{X}^T \mathbf{y}$.
7. Calculer les estimations MCO des paramètres, c'est-à-dire calculer $(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$. Vérifier le résultat obtenu en soumettant l'instruction `lm(mpg~1+hp+wt,data=mtcars)` dans la console.

Exercice 7 : Data-frame

1. Charger le package `MASS`.
2. A partir du jeu de données `iris` disponible sous R (utiliser `data(iris)` pour le charger puis `head(iris)` pour en visualiser les premières lignes), créer un jeu de données `iris2` ne contenant que les données pour lesquelles la variable `Species` prend la modalité `versicolor`.
3. Trier par ordre décroissant les données de `iris2` en fonction de la variable `Sepal.Length` (utiliser la fonction `order`).
4. A quel type d'objet appartient `iris$Species`?
5. Soumettre la commande `by(iris$Sepal.Width, iris$Species, mean)` et commenter la sortie obtenue.

Exercice 8 : Utilisation des fonctions `apply`, `lapply`

1. (a) Calculer les statistiques de base (moyenne, min, max, etc) des trois variables du jeu de données `ethanol` (disponible sous R dans le package `lattice`).
- (b) Calculer les quartiles de chacune des trois variables (utiliser pour cela la fonction `apply` avec la fonction `quantile`).
- (c) Toujours avec la fonction `apply`, calculer tous les déciles de chacune des trois variables en utilisant l'argument `probs` de la fonction `quantile`.
2. Charger le jeu de données `Aids2` du package `MASS` et le résumer (`summary`). Soumettre le code suivant et commenter les actions réalisées :

```

indice=!unlist(lapply(Aids2,is.numeric))
Aids2.qual=Aids2[,indice]
lapply(Aids2.qual,levels)

```

Exercice 9 : Importation de données et fusion de tables

1. Importer dans R les fichiers `test1.csv`, `test2.csv` et `test3.csv` après en avoir examiné le contenu (voir par exemple la ligne 130 des fichiers `test2.csv` et `test3.csv`).
2. (a) Importer les fichiers `etat1.csv`, `etat2.csv` et `etat3.csv`.
- (b) Fusionner les trois data-frames en un seul en utilisant les colonnes communes.