Courte initiation à R

Résolution de Problèmes d'Optimisation
Master 1 informatique I2L / WeDSci

Sébastien Verel
verel@univ-littoral.fr
http://www-lisic.univ-littoral.fr/~verel

Université du Littoral Côte d'Opale
Laboratoire LISIC
Equipe OSMOSE

Plan

Logiciel R

Historique

- `R` est un logiciel libre (projet GNU), open source
- Langage et environnement dédié au traitement statistique et à la représentation graphique des données
- Clone du logiciel $S+$ (qui n'est pas libre)
- Disponible sous toutes les plateformes : `http://www.r-project.org`
- Enormement de librairies disponibles (très pointues), projet très dynamique
- Langage basé sur le calcul matriciel de la même famille que Matlab, Scilab

Logiciel R

Aide

Documentation

Très nombreuses documentations (livres, site web, forums, etc.)
Un site parmi d'autres :
`http://www.duclert.org/Aide-memoire-R/Le-langage/Introduction.php`

Aide en ligne

Pour avoir de l'aide sur une fonction :

`help(mean)`

ou

`?mean`

Environnement

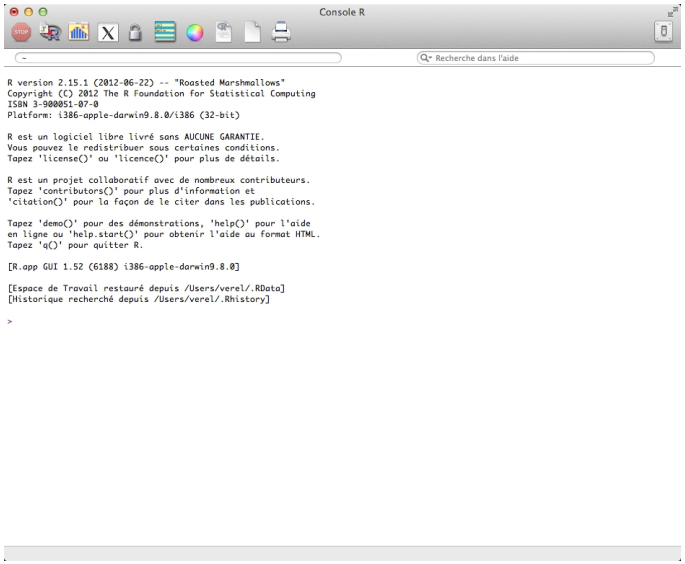

- Les commandes peuvent être exécutées directement en les frappant au niveau du prompt
- Possibilité d'écrire des scripts (extension `.R`), lecture : `source("blabla.R", echo = T)`
- Pour quitter la session : `q()`
- L'historique peut être enregistrer pour ne pas perdre les données (fichier `.Rhistory`)

Calculatrice

- le "top level" peut être utilisé comme une calculatrice :
  ```
  sqrt(3 * 3 + 4 * 4)
  sin(pi / 2)
  ```
- Notion de variable :
  ```
  a <- 2
  a <- a + 1
  ```
- Lister l'ensemble des variables de l'environnement :
  ```
  ls()
  ```
- Effacer une variable de l'environnement :
  ```
  rm(a)
  ```

Vecteurs

- Objets de base de `R`
- Suite d'éléments de même type :
  - numérique (réelles ou complexes),
  - booléen (`TRUE, FALSE`)
  - alphanumérique (chaine de caractères)

```
c(elt1, elt2, elt3, ...)
```

Vecteurs

Création

- En extension (c pour combine) :
  `c(100, 20, 50)`
  vecteur composé des 3 entiers 100, 20 et 50.
- Par "répétition" d'un élément avec `rep` :
  `rep("a", 20)`
  vecteur composé de 20 éléments égaux au caractère "a"
- Par description d'une suite d'entiers consécutifs avec " :" :
  `1:100`
  vecteur composé des 100 premiers entiers
- Par description d'une suite d'entiers consécutif avec `seq` :
  `seq(11, 31, 2)`
  vecteur composé des nombres impairs entre 11 et 31.

Vecteurs

Longueur

- La longueur d'un vecteur est donné par `length` :
  `length(rep(1, 100))` donne 100

Concaténation

- L'ajout d'éléments s'effectue dela manière suivante :
  `u <- c(100, 20, 50)`
  `u <- c(u, 500)`
  donne : 100, 20, 50, 500

Tirage sans remise

- `sample` effectue un tirage sans remise des éléments :
  `sample(1:100, 10)`
  donne un vecteur constitué de 10 valeurs aléatoirement sélectionnées sans remise parmi le vecteur 1:100

Vecteurs

Lecture / ecriture

- Pour accèder à un élément donnée :
  `u[2]`
  élément d'indice 2 du vecteur u
- Attention le premier élément est d'indice 1 !
  `u <- c(100, 20, 50)`
  `u[1]` a pour valeur 100
- Sous-vecteur :
  `u[2:50]`
  éléments de l'indice 2 à l'indice 50.
  `u[c(2, 4, 6)]`
  éléments d'indice 2, 4 et 6.
- Sous-vecteur avec sélection :
  `u[u > 0]`
  vecteur composé des éléments strictement positifs de u

Opération sur les vecteurs

- Les opérations sont rapides et ne nécessite pas de boucles :
  `u + v`
  somme du vecteur u et v
- Opération sur chaque élément :
  `u * 2`
  multiplie tous les éléments par 2
- Application de fonction :
  `sin(u)`
  applique la fonction sinus à tous les éléments
- Tests :
  `u <- c(100, 20, 50)`
  `u > 30`
  donne le vecteur dont les éléments sont le résultat du test
  `TRUE FALSE TRUE`

Nom des éléments

- Par défaut, les éléments sont indexés par des entiers
- Il est possible de donner des noms aux éléments :
  `u <- c(100, 20, 50)`
  `names(u) <- c("un", "deux", "trois")`
  `u["un"]` a pour valeur 100
- Connaitre les noms des éléments :
  `names(u)`
  `"un", "deux", "trois"`

Matrices

- Objets de base de `R`
- Tableau à 2 dimensions d'éléments de même type :
  - numérique (réelles ou complexes),
  - booléen (`TRUE, FALSE`)
  - alphanumérique (chaine de caractères)

Matrices

Création

- En "colonne" :

```
A <- matrix(c(1:6), ncol = 2)
```

```
     [,1] [,2]
[1,]    1    4
[2,]    2    5
[3,]    3    6
```

- En "ligne" :

```
A <- matrix(c(1:6), ncol = 2, byrow=TRUE)
```

```
     [,1] [,2]
[1,]    1    2
[2,]    3    4
[3,]    5    6
```

Matrices

Lecture / écriture

```
A <- matrix(c(1:6), ncols = 2)
```

- Notation matricielle usuelle :
  `A[1,2]` a pour valeur 4
- une ligne entière :
  `A[1,]`
  la première ligne
- une colonne entière :
  `A[,2]`
  la deuxième colonne

Matrices

Opérations

- Opérations terme à terme : `A + B`
  `A * B`
- Opérations matricielles usuelles :
  `A %*% B`

Listes

Liste

- Suite d'objets (vecteurs, matrices, etc.) qui ne sont pas nécessairement du même type
- Utilisées par de nombreuses fonctions en résultat

Listes

Création

- Utilisation du mot clé `list` :

```
maSuperListe <- list(je = c("pense", "suis"),
data = matrix(c(1:6) ncols = 2))
```

Listes

Création

- Utilisation du mot clé `list` :
  `maSuperListe <- list(je = c("pense", "suis"), data = matrix(c(1:6) ncols = 2))`

Lecture / écriture

- Utilisation du signe $:
  `maSuperListe$je` donne l'élément `je` de la liste
- Utilisation du double crochet :
  `maSuperListe[[1]]` donne le premier élément de la liste (= `maSuperListe$je`)

Les `data.frame`

`data.frame`

- Liste de plusieurs vecteurs de même longueur
- Proche de la notion de tableau

Les `data.frame` : Création

Fichier csv

- Les fichiers d'extension `.csv` (comma-separated values) ont pour convention d'être des fichiers textes où les données sont enregistrées sous forme de tableau (ligne / colonne)
- Sur une même ligne, les données sont séparées par un caractère (espace, virgule, etc.)

```
initial final
155.209786 118.799252
367.658596 118.795867
405.252902 118.795936
...
```

Les `data.frame` : Création

Création à partir d'un fichier

- Les data frame peuvent se construire à partir d'un fichier csv :
  `frame <- read.table("data.csv", sep = " ", header = TRUE)`
  - le premier argument est le nom du fichier
  - `sep` indique le caractère de séparation des données
  - `header` indique si la première ligne contient le nom des colonnes

Les `data.frame` : Création

Création à partir d'un fichier

- Les data frame peuvent se construire à partir d'un fichier csv :
  `frame <- read.table("data.csv", sep = " ", header = TRUE)`
  - le premier argument est le nom du fichier
  - `sep` indique le caractère de séparation des données
  - `header` indique si la première ligne contient le nom des colonnes

Lecture / écriture

Pour obtenir les vecteurs constituant le data frame :

- Utilisation du signe $:
  `frame$initial`
- Utilisation du double crochet :
  `frame[[1]]`

Les fonctions

Fonction définie par l'utlisateur

```
maFonction <- function(arg1, arg2) {
    bloc d'instructions
}
```

- Le dernier résultat du bloc d'instruction est la valeur finale de la fonction

Exemple

```
plusUn <- function(x) {
    x + 1
}
```

Branchements et Itérations

si ... alors ... sinon ...

```
if (x < 0)
   - x
else
   x
```

Itération "pour"

```
for(name in c("un", "deux", "trois"))
   print(name)
```

Itération "tant que"

```
i <- 0
while(i < 100) {
   print(i)
   i <- i + 1
}
```

Statistique descriptive

- Moyenne :
  `mean(u)`
- Variance :
  `var(u)`
- Ecart-type :
  `sd(u)`
- Minimum et maximum :
  `min(u)`
  `max(u)`
- Quartiles :
  `quantile(u)`
- Résumé des principales statistiques :
  `summary(u)`

Observation d'une distribution empirique

Histogramme

```
hist(u)
```

Boite à moustache

- Unique :
  `boxplot(u)`
- Plusieurs vecteurs :
  `boxplot(list(u, v))`

Loi normale

Loi normale ou loi gaussienne

- Loi adaptée à modéliser de nombreux phénomènes naturels aléatoires
- Complètement caractérisée par la moyenne μ et la variance σ^2
- Densité :

$$\frac{1}{\sigma 2\pi} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

- Notation :

$$X \sim \mathcal{N}(\mu, \sigma^2)$$

en R

- Obtenir des réalisations :
  `rnorm(1000, 0, 1)`
  1000 réalisations d'une loi normale de moyenne nulle et de variance 0.

Données bivariées

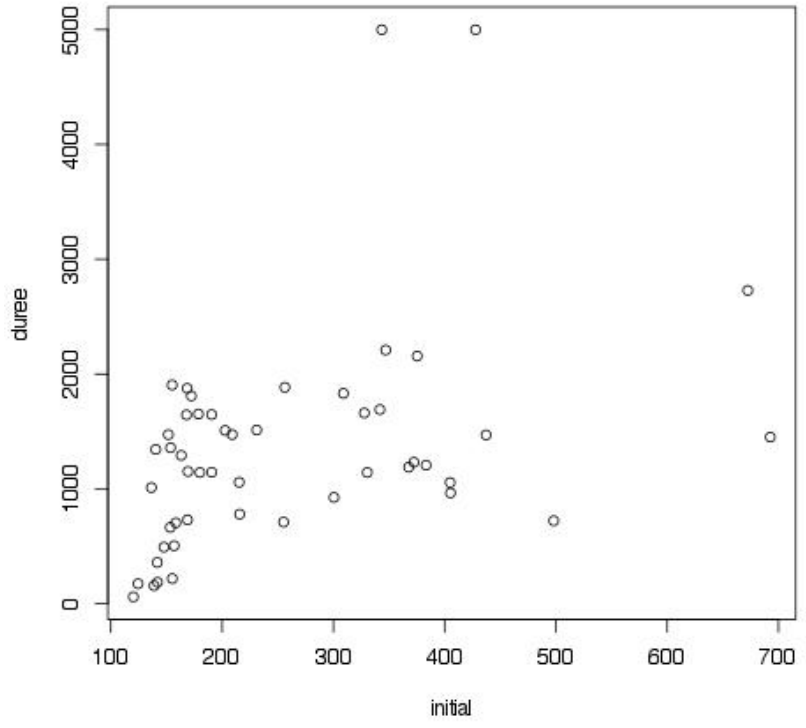

Définition

Ensemble de couples de données $\{(x_1, y_1), (x_2, y_2), \ldots\}$

en R

- Si `x` et `y` sont des vecteurs de même longueur (abscisses et ordonnées) :
  `plot(x,y)`
- Si `frame` est un data.frame (`initial` et `duree` sont des colonnes) :
  `plot(duree ~ initial, frame)`

Statistique inférentielle

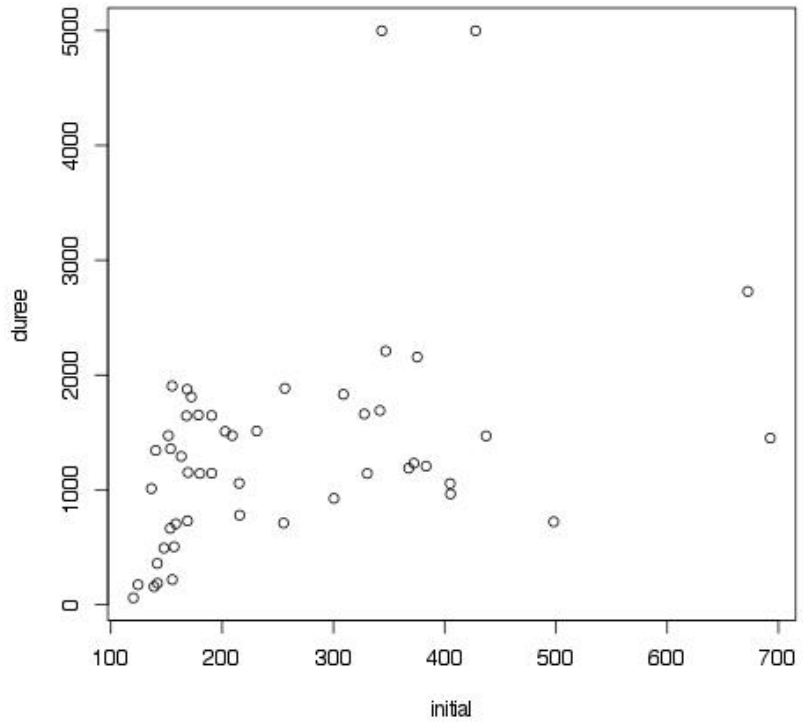

Questions

Existe-t-il une relation entre les variables x et y ?
Laquelle ?

Modèle linéaire

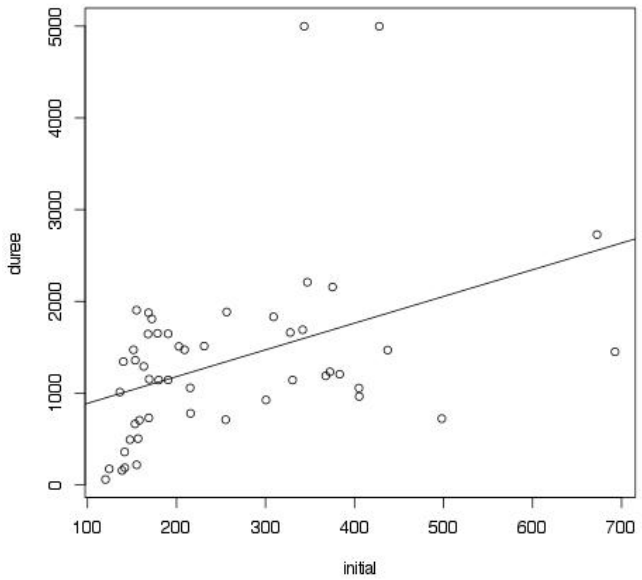

Modèle linéaire

Le nuage de point est remplacé par une droite :

$$y = a.x + b$$

On peut alors :

- Expliquer la relation entre les variables
- Prédir les valeurs

Modèlisation et erreur

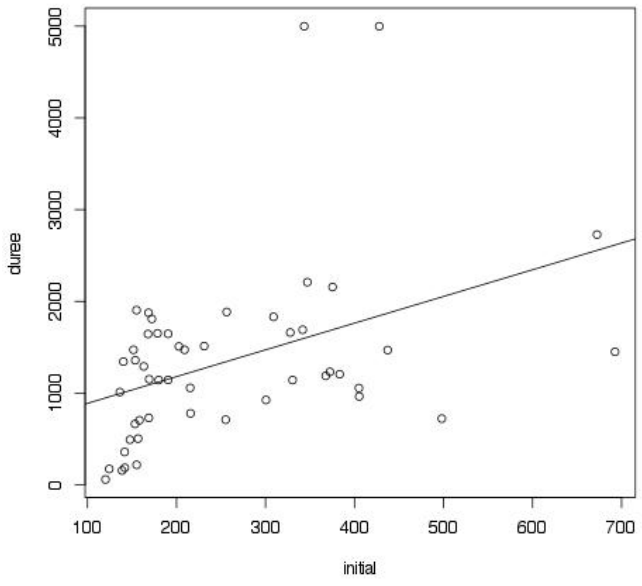

Erreur quadratique moyenne (MSE)

Erreur du modèle est la distance entre observations et prédictions :

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(f(x_i) - y_i)^2$$

D'autres mesures de distance sont possibles...

Modèlisation et erreur

Ajustement du modèle

$$f(x) = a.x + b$$

- Choisir les paramètres du modèle pour minimiser l'erreur
- Choisir a et b pour minimiser l'erreur MSE
- L'erreur est alors égale au coefficient de corrélation (au signe prêt) :

$$\rho = \frac{cov(x, y)}{\sigma_x \sigma_y}$$

Modèle linéaire en R

Fonction `lm`

- Utiliser la fonction `lm` (linear model) :
  - Avec data.frame :
    `lin <- lm(y ~ x, frame)`
  - Avec vecteurs de même longueur :
    `lin <- lm(x, y)`
- Pour avoir le descriptif du modèle :
  `summary(lin)`
- En particulier, on peut lire la p-value du modèle :
  Si p-value < 0.05, le modèle linéaire est significatif
- Pour avoir les coefficients a et b :
  `lin$coefficients`

Corrélation R

- Utiliser la fonction `cor` :
  - Avec data.frame :
    `cor(frame)`
    On obtient une matrice de corrélation entre toutes les variables du data.frame
  - Avec vecteurs de même longueur :
    `cor(x, y)`
- Si le coefficient est négatif, les variables sont anti-corrélées (variation inverse)
- Un fort coefficient est supérieur à 0.8 ou 0.9 (en valeur absolue)
- Un faible coefficient est compris entre -0.2 ou 0.2