

Rééchantillonnage sous R : bootstrap et jackknife

Loïc PONGER

MNHN

USM 503 Régulation et Dynamique des Génomes

ponger@mnhn.fr

Rééchantillonnage sous R

bootstrap et jackknife

Ponger Loic

MNHN-USM503
43 ru Cuvier
75005 Paris

6 mai 2008

Méthodes statistiques basées sur un rééchantillonnage des données à partir d'une distribution estimée de la population réelle (inconnue). Cette distribution est "souvent" construite à partir de l'échantillon observé.

Objectifs

- ⇒ estimer un intervalle de confiance autour d'un paramètre,
- ⇒ construire un test d'hypothèse,
- ⇒ identifier des valeurs aberrantes (jackknife).

Propriétés

- ⇒ simple, paramétrique vs. **non-paramétrique**,
- ⇒ "computer intensive"

1 Bootstrap

- présentation
- la fonction boot
- la fonction boot.ci
- les autres fonctions

Jackknife

- présentation
- la fonction jackknife
- la fonction jack.after.boot

1 Bootstrap

- **présentation**
- la fonction boot
- la fonction boot.ci
- les autres fonctions

Jackknife

- **présentation**
- la fonction jackknife
- la fonction jack.after.boot





On calcule une statistique (moyenne, médiane, r^2 , ...) à partir d'un échantillon de n individus issues de la pop. d'étude. La distribution de la population est inconnue ou non-normale. Le bootstrap permet de construire une distribution proche de la distribution inconnue.

Algorithme

- Calcul de la statistique observée
- Pour i allant de 1 à n_b
 - échantillonnage **aléatoire** avec **remise** de n individus parmi l'échantillon observé
 - calcul de la statistique sur le $i^{\text{ème}}$ échantillon de bootstrap
- Calcul la fonction de distribution à partir des n_b valeurs de la statistique \Rightarrow intervalle de confiance ou autre

Hyp de travail : les individus sont indépendants et identiquement distribués (i.i.d.)

Le bootstrap : principe



population étudiée
(μ)

échantillon observé
(\bar{x})

B échantillons de
bootstrap
(\bar{x}^*)

distribution des \bar{x}^*
(moyenne des \bar{x}^*)

Algorithme

```
### Les données
goudron=c(0.45,0.77,1.07,1.03,1.34,1.14,1.15,0.9,0.55,1.15)
nicotine=c(11,13,14,15,17,18,14.5,13.5,8.5,16.5)
tabac=cbind(goudron,nicotine)
l=length(nicotine)
```

```
tabac
  goudron nicotine
[1,]  0.45    11.0
[2,]  0.77    13.0
[3,]  1.07    14.0
[4,]  1.03    15.0
[5,]  1.34    17.0
[6,]  1.14    18.0
[7,]  1.15    14.5
[8,]  0.90    13.5
[9,]  0.55     8.5
[10,] 1.15    16.5
```

Exemple issu de Tomassone R., Charles-Bajard S. et Bellanger L. (1998)

Algorithme

```
### La fonction pour calculer la statistique à
### partir des indices
functionCor=function(val, ii){
cor( val[ii,1] , val[ ii,2] )
}

### Corrélation observée
functionCor(tabac,1 :1)
0.8901696
```

Exemple issu de Tomassone R., Charles-Bajard S. et Bellanger L. (1998)

Algorithme

```
### Bootstrap
NB=1000
bootCor=vector(length=NB)
for (ind in 1 :NB) {
  bootIndice=sample(1 :l, replace=T)
  bootCor[ind]=functionCor(tabac, bootIndice)
}

### calcul de l'IC à 95%
quantile(bootCor, c(0.025, 0.975))
  2.5%    97.5%
0.7175133 0.9731658
```

Exemple issu de Tomassone R., Charles-Bajard S. et Bellanger L. (1998)

Deux bibliothèques

bootstrap permet également de faire du jackknife, (d'après Efron et Tibshirani, 1994), maintenue par K. Halvorsen

boot plus de fonctionnalités (d'après Davison et Hinkley, 1997), maintenue par B. Ripley

1 Bootstrap

- présentation
- la fonction boot
- la fonction boot.ci
- les autres fonctions

Jackknife

- présentation
- la fonction jackknife
- la fonction jack.after.boot

Algorithme

```
library(boot)

### Les données
goudron=c(0.45,0.77,1.07,1.03,1.34,1.14,1.15,0.9,0.55,1.15)
nicotine=c(11,13,14,15,17,18,14.5,13.5,8.5,16.5)
tabac=cbind(goudron,nicotine)
l=length(nicotine)

### Définition de la fonction pour le calcul de la statistique

myCor <- function(data, indice){
  cor(data[indice,1],data[indice,2])
}

b=boot(tabac, statistic=myCor, R=1000, sim="ordinary", stype="i")
```

On utilise ici la fonction `boot` de la bibliothèque `boot`. On pourrait également utiliser la fonction `bootstrap` (bibliothèque `bootstrap`) mais l'utilisation de la fonction pour le calcul de la statistique est différent.

Algorithme

```
summary(b)
  Length Class  Mode
t0      1  -none- numeric
t       1000  -none- numeric
R        1  -none- numeric
data    20   -none- numeric
seed    626  -none- numeric
statistic 1  -none- function
sim      1  -none- character
call     6  -none- call
stype    1  -none- character
strata   10  -none- numeric
weights  10  -none- numeric
```

On utilise ici la fonction `boot` de la bibliothèque `boot`. On pourrait également utiliser la fonction `bootstrap` (bibliothèque `bootstrap`) mais l'utilisation de la fonction pour le calcul de la statistique est différent.

Algorithme

```
summary(b$t)
  V1
Min.   :0.4840
1st Qu.:0.8774
Median :0.9061
Mean   :0.8947
3rd Qu.:0.9302
Max.   :0.9939
```

On utilise ici la fonction `boot` de la bibliothèque `boot`. On pourrait également utiliser la fonction `bootstrap` (bibliothèque `bootstrap`) mais l'utilisation de la fonction pour le calcul de la statistique est différent.

```
boot(data, statistic, R, sim="ordinary", stype="i", ...)
```

les arguments

data vecteur ou table (observations sur les lignes)

statistic fonction retournant la valeur de la statistique

R nombre de réplicats

sim type de bootstrap (ordinary, parametric, ...)

stype dépend de la fonction utilisée

- indices : **i**, numéros des lignes sélectionnées (certains numéros apparaissent plusieurs fois)
- fréquences (absolues) : **f**, un entier correspondant au nombre de sélection de chaque ligne (somme est égale au nombre d'observations initiales)
- poids : **w**, un réel compris entre 0 et 1 (somme est égale à 1)

les sorties

t_0 la statistique calculée sur les données

t les valeurs de la statistiques calculées sur les répliquats (R valeurs)

...

la fonction statistique

Elle est calculée par une fonction prenant au moins 2 arguments :

le premier les données

le second un vecteur avec les indices/poids/fréquences des valeurs sélectionnées (par la fonction boot). Si les données sont sous la forme de tableau, les indices représentent les numéros de lignes.

option des arguments qui seront passés via boot

Une fonction calculant la moyenne à partir des indices :

```
statistic=function(valeurs,indices){  
  sum(valeurs[indices])/length(indices)  
}  
boot(data, stat=statistic, R=1000, stype="i")
```

la fonction statistique

Elle est calculée par une fonction prenant au moins 2 arguments :

le premier les données

le second un vecteur avec les indices/poids/fréquences des valeurs sélectionnées (par la fonction boot). Si les données sont sous la forme de tableau, les indices représentent les numéros de lignes.

option des arguments qui seront passés via boot

Une fonction calculant la moyenne à partir des fréquences :

```
statistic=function(valeurs,frequences){  
  sum(valeurs*frequences)/sum(frequences)  
}
```

```
boot(data, stat=statistic, R=1000, stype="f")
```

la fonction statistique

Elle est calculée par une fonction prenant au moins 2 arguments :

le premier les données

le second un vecteur avec les indices/poids/fréquences des valeurs sélectionnées (par la fonction boot). Si les données sont sous la forme de tableau, les indices représentent les numéros de lignes.

option des arguments qui seront passés via boot

Une fonction calculant une moyenne à partir de poids (sens?) :

```
statistic=function(valeurs,poids){  
  sum(valeurs*poids)/1  
}
```

```
boot(data, stat=statistic, R=1000, stype="w")
```

la fonction statistique

Elle est calculée par une fonction prenant au moins 2 arguments :

le premier les données

le second un vecteur avec les indices/poids/fréquences des valeurs sélectionnées (par la fonction boot). Si les données sont sous la forme de tableau, les indices représentent les numéros de lignes.

option des arguments qui seront passés via boot

Une fonction calculant la moyenne en utilisant mean (et un troisième arg.) :

```
statistic=function(valeurs, indices, t){  
  mean(valeurs[indices], trim=t)  
}  
boot(data, stat=statistic, R=1000, stype="i", t=0.25)
```

les différents type de ré-échantillonnage

ordinary bootstrap Chaque échantillon de bootstrap est issu d'un tirage aléatoire. Les échantillons sont indépendants des précédents.

parametric bootstrap Les n_b échantillons sont construits à partir d'une distribution théorique dont les paramètres de position et de variabilité sont estimés à partir de l'échantillon.

balanced bootstrap Chaque valeur apparaît n_b fois parmi tous les n_b rééchantillonnages. Augmente la précision de SE.

antithetic resampling Chaque échantillon de bootstrap est construit en utilisant les couples $(i, n-i)$. Réduit la variance de la statistique.

permutation Chaque échantillon de bootstrap est composé par une permutation aléatoire des n valeurs.

1 Bootstrap

- présentation
- la fonction boot
- la fonction boot.ci
- les autres fonctions

Jackknife

- présentation
- la fonction jackknife
- la fonction jack.after.boot

les 5 types d'estimation des CI

- normal** Utilisation d'une loi normale dont les paramètres (moyenne et variance) sont estimés à partir de la distribution empirique.
- basic** Utilisation la distribution des $\hat{\theta}_i - \hat{\theta}$.
- student** Utilisation de la distribution des $t_i = \frac{\hat{\theta}_i - \hat{\theta}}{s_{\hat{\theta}_i}}$.
- percent** Utilisation de la distribution empirique des $\hat{\theta}_i$
 - bca** Bias Corrected and Accelerated. Transformation de la distribution empirique en une loi normale centrée réduite. Correction pour l'asymétrie.

Voir : Carpenter and Bithell (2000) (papier relativement simple et clair)

1 Bootstrap

- présentation
- la fonction boot
- la fonction boot.ci
- les autres fonctions

Jackknife

- présentation
- la fonction jackknife
- la fonction jack.after.boot

censboot fonction de bootstrap pour données "right-censored"

tsboot fonction de bootstrap pour des séries temporelles (découpage en blocs)

tilt.boot fonction de bootstrap basée sur un "importance resampling"

empinf retourne l'influence empirique des valeurs sur la statistique étudiée à partir d'un objet boot

boot.array retourne un tableau $n * n_b$ avec les fréq. de chaque individu à partir d'un objet boot

jack.after.boot effectue un jackknife sur un objet boot.

1 Bootstrap

- présentation
- la fonction boot
- la fonction boot.ci
- les autres fonctions

2 Jackknife

- présentation
- la fonction jackknife
- la fonction jack.after.boot

1 Bootstrap

- présentation
- la fonction boot
- la fonction boot.ci
- les autres fonctions

2 Jackknife

- **présentation**
- la fonction jackknife
- la fonction jack.after.boot

On calcule une statistique (moyenne, médiane, r^2 , ...) à partir d'un échantillon de n individus issues de la pop. d'étude. La distribution de la population est inconnue ou non-normale. Le jackknife permet de construire une distribution proche de la distribution inconnue.

Algorithme

- Calcul de la statistique observée
- Pour i allant de 1 à n
 - échantillonnage de tous les individus, **sauf le i^{ieme}**
 - calcul de la statistique sur le i^{ieme} échantillon de bootstrap
- Calcul la fonction de distribution à partir des n valeurs de la statistique \Rightarrow intervalle de confiance ou autre
- Analyse des n valeurs de la statistique à la recherche de valeurs aberrantes

Algorithme

```
### Les données
goudron=c(0.45,0.77,1.07,1.03,1.34,1.14,1.15,0.9,0.55,1.15)
nicotine=c(11,13,14,15,17,18,14.5,13.5,8.5,16.5)
tabac=cbind(goudron,nicotine)
l=length(nicotine)
```

```
tabac
```

```
  goudron nicotine
[1,]  0.45    11.0
[2,]  0.77    13.0
[3,]  1.07    14.0
[4,]  1.03    15.0
[5,]  1.34    17.0
[6,]  1.14    18.0
[7,]  1.15    14.5
[8,]  0.90    13.5
[9,]  0.55     8.5
[10,] 1.15    16.5
```

Algorithme

```
### La fonction pour calculer la statistique à
### partir des indices
functionCor=function(val, removed){
cor( val[ -removed,1] , val[ -removed,2] )
}

### Corrélation observée
functionCor(tabac,1 :1)
0.8901696
```

Algorithme

```
### Jackknife
jackCor=vector(length=1)
for (ind in 1 :l) {
  jackCor[ind]=functionCor(tabac, ind)
}

### calcul de l'IC à 95%
quantile(jackCor, c(0.025, 0.975))
  2.5%    97.5%
0.8722099 0.9126298
```

1 Bootstrap

- présentation
- la fonction boot
- la fonction boot.ci
- les autres fonctions

2 Jackknife

- présentation
- la fonction jackknife
- la fonction jack.after.boot

Algorithme

```
library(bootstrap)

### Les donnéesgoudron=c(0.45,0.77,1.07,1.03,1.34,1.14,1.15,0.9,0.55,1.15)
nicotine=c(11,13,14,15,17,18,14.5,13.5,8.5,16.5)
tabac=cbind(goudron,nicotine)
l=length(nicotine)

### Définition de la fonction pour le calcul de la statistique

myCor <- function(indice, data){
  cor(data[indice,1],data[indice,2])
}

j=jackknife( 1 :l,      myCor,      data=tabac)
```

Algorithme

```
summary(j)
```

	Length	Class	Mode
jack.se	1	-none-	numeric
jack.bias	1	-none-	numeric
jack.values	10	-none-	numeric
call	4	-none-	call

```
summary(j$jack.values)
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
0.8710	0.8848	0.8902	0.8923	0.9012	0.9146

R : La fonction jackknife

Utiliser le package `bootstrap` :

les arguments

- `x` le vecteur de valeurs
- `theta` la fonction calculant la statistique La fonction `theta` reçoit le vecteur `x` privé du i^{ieme} élément comme argument.


Attention : la fonction `theta` du package `bootstrap` ne fonctionne pas comme celle du package `boot`.

les sorties

- `jack.se` : déviation standard de la statistique
- `jack.bias` : biais de la statistique
- `jack.values` : les `n` valeurs obtenues en retirant successivement les `n` individus

Le jackknife pour identifier les valeurs aberrantes

```
j=jackknife( 1:1,      myCor,      data=tabac)}\only<2>{\nplot(j$jack.values)
```



R : comment écrire la fonction theta

Données simples : on peut fournir la liste des valeurs x . La fonction jackknife "élimine" le i^{ieme} individu de x et lance la fonction theta avec les valeur restantes.

jackknife sur les valeurs x_i

```
x <- rnorm(20)
theta <- function(x)mean(x)
results <- jackknife(x,theta)
```

Données complexes : il faut stocker les données dans un tableau et fournir la liste des lignes à traiter. La fonction jackknife "élimine" la i^{ieme} ligne de x et lance la fonction theta avec les numéros de lignes restantes. Le tableau doit être passé en argument supplémentaire.

jackknife sur les indices i

```
xdata <- matrix(rnorm(30),ncol=2)
n <- 15
theta <- function(x,xdata) cor(xdata[x,1],xdata[x,2])
results <- jackknife(1 :n,theta,xdata)
```

1 Bootstrap

- présentation
- la fonction boot
- la fonction boot.ci
- les autres fonctions


2 Jackknife

- présentation
- la fonction jackknife
- la fonction jack.after.boot

Le jackknife après le bootstrap

Objectif : identifier des valeurs aberrantes parmi les n_b bootstraps

```
library(boot)  
jack.after.boot(b)
```



- approche générale** P. Hall (2003) A Short Prehistory of the Bootstrap. Statist. Sci., 18 :158-167.
- approche générale** P. M. Dixon (2002) Bootstrap resampling. Encyclopedia of Environmetrics, 1 :212-220
- calcul des CI** J. carpenter and J. Bithell (2000) Bootstrap confidence intervals : when, which, what ? A practical guide for medical statisticians. Statistics in Medicine. 19 :1141-1164.
- exemples** <http://www.stat.umn.edu/geyer/old03/5601/examp>