

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Une introduction au monde du Bootstrap

Bruffaerts Christopher

European Center for Advanced Research in Economics and Statistics (ECARES)

Août 5, 2013

Quand on google le mot “Bootstrap”...

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et faiblesses

Le bootstrap en action

Exemple 1

Exemple 2

Conclusion

Quand on google le mot "Bootstrap"...

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

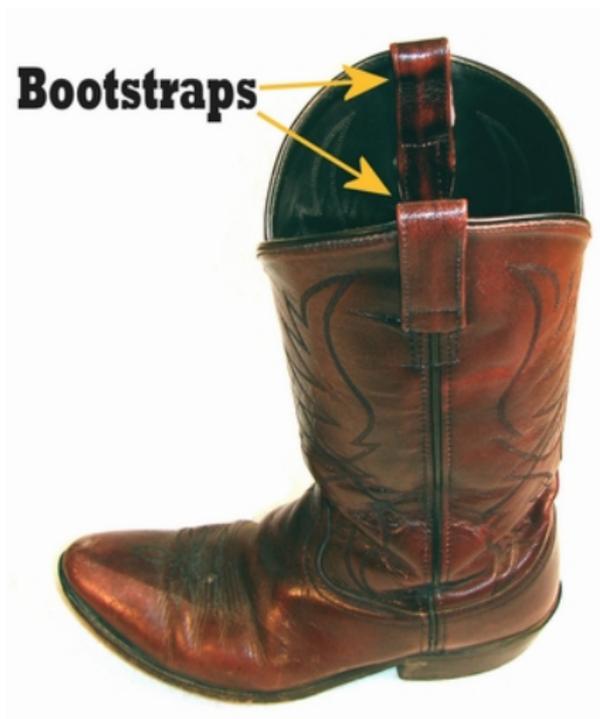
Forces et faiblesses

Le bootstrap en action

Exemple 1

Exemple 2

Conclusion



Agenda

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et faiblesses

Le bootstrap en action

Exemple 1

Exemple 2

Conclusion

1 Introduction

2 Le bootstrap

3 Algorithme

4 Forces et faiblesses

5 Le bootstrap en action

6 Conclusion

Population VS échantillon

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

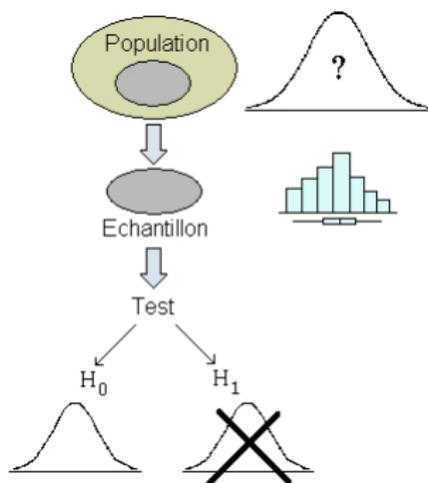
Forces et
faiblessesLe bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Inférence statistique



Population VS échantillon

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

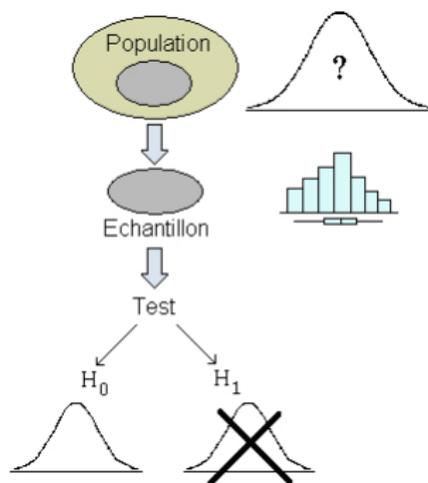
Forces et
faiblessesLe bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Inférence statistique



Domaines d'application de la statistique: Sondages, plans d'expérience, modèles de survie, GLM, contrôle de qualité, statistique spatiale, séries temporelles, ...

Paramétrique VS non Paramétrique

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en action

Exemple 1

Exemple 2

Conclusion

Soit un échantillon i.i.d. $\mathcal{X} = (X_1, X_2, \dots, X_n)$ issu d'une population dont la fonction de répartition est $F(x) = P[X \leq x]$.

Paramétrique VS non Paramétrique

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Soit un échantillon i.i.d. $\mathcal{X} = (X_1, X_2, \dots, X_n)$ issu d'une population dont la fonction de répartition est $F(x) = P[X \leq x]$.

- $F(\cdot) = F_\theta(\cdot)$ où $\theta \in \mathbb{R}^k \Rightarrow$ **paramétrique**.
 - La teneur en sucre de bonbons: $X \sim \mathcal{N}(\mu, \sigma^2)$ avec $\theta = (\mu, \sigma^2)'$.
 - Nombre d'accidents sur un laps de temps: $X \sim \mathcal{P}(\lambda)$ avec $\theta = \lambda > 0$.
 - La durée de vie d'ampoules: $X \sim Exp(\lambda)$ avec $\theta = \lambda > 0$.
- $F(\cdot)$ inconnue \Rightarrow **non-paramétrique**.
 - Tests de signes
 - Tests de rangs

Paramètres d'intérêt

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Fonctionnelle statistique: fonction à valeur réelle dont l'argument est une fonction de répartition.

Paramètres d'intérêt

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblessesLe bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Fonctionnelle statistique: fonction à valeur réelle dont l'argument est une fonction de répartition.

Exemples:

- *Moyenne*: $\theta = T(F) = \int x dF(x)$.

ex.: Age moyen des étudiants de l'ULB.

- *Variance*: $\theta = T(F) = \int x^2 dF(x) - \left(\int x dF(x) \right)^2$.

ex.: Pourcentage de viande de cheval dans les boulettes IKEA.

- *Quantile*: $\theta = T(F) = F^{-1}(\alpha)$, $\alpha \in [0, 1]$.

ex.: Revenu médian de la population belge.

Paramètres d'intérêt

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblessesLe bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Fonctionnelle statistique: fonction à valeur réelle dont l'argument est une fonction de répartition.

Exemples:

- *Moyenne*: $\theta = T(F) = \int x dF(x)$.

ex.: Age moyen des étudiants de l'ULB.

- *Variance*: $\theta = T(F) = \int x^2 dF(x) - \left(\int x dF(x) \right)^2$.

ex.: Pourcentage de viande de cheval dans les boulettes IKEA.

- *Quantile*: $\theta = T(F) = F^{-1}(\alpha)$, $\alpha \in [0, 1]$.

ex.: Revenu médian de la population belge.

Question: Comment estimer ces paramètres à partir de l'échantillon?

F inconnue mais F_n est connue !

Fonction de répartition empirique

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithmes

Non Paramétrique

Paramétrique

Forces et
faiblessesLe bootstrap en
action

Exemple 1

Exemple 2

Conclusion

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}(X_i \leq x)$$

Par le théorème de **Glivenko-Cantelli**, $F_n(x) \xrightarrow{P} F(x)$



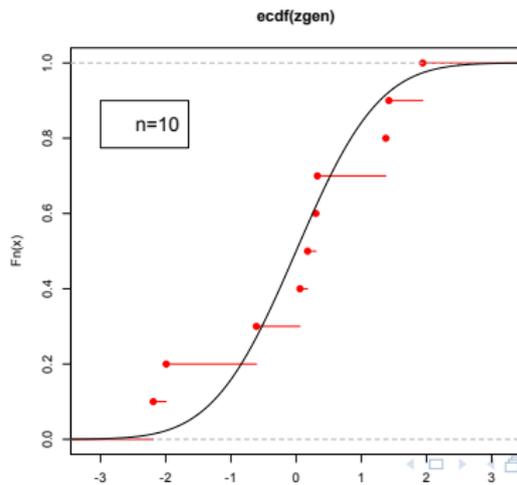
Fonction de répartition empirique

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}(X_i \leq x)$$

Par le théorème de **Glivenko-Cantelli**, $F_n(x) \xrightarrow{P} F(x)$



Figure: Fonction de répartition de $\mathcal{N}(0, 1)$ et sa version empirique.



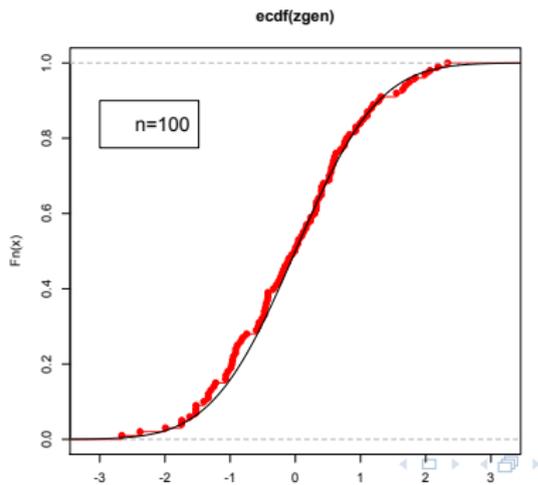
Fonction de répartition empirique

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}(X_i \leq x)$$

Par le théorème de **Glivenko-Cantelli**, $F_n(x) \xrightarrow{P} F(x)$



Figure: Fonction de répartition de $\mathcal{N}(0, 1)$ et sa version empirique.



Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

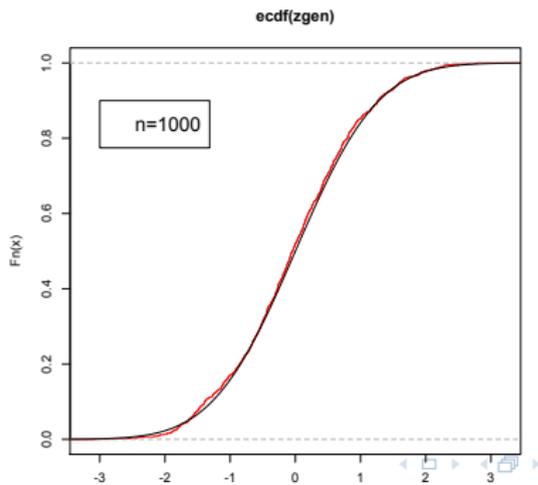
Fonction de répartition empirique

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}(X_i \leq x)$$

Par le théorème de **Glivenko-Cantelli**, $F_n(x) \xrightarrow{P} F(x)$



Figure: Fonction de répartition de $\mathcal{N}(0, 1)$ et sa version empirique.



Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Estimation: Principe du plug-in

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Soit l'échantillon i.i.d. $\mathcal{X} = (X_1, \dots, X_n)$.

Exemples:

- *Moyenne*: $\hat{\theta} = T(F_n) = \int x dF_n(x) = \frac{1}{n} \sum_{i=1}^n X_i$.

- *Variance*:

$$\hat{\theta} = \int x^2 dF_n(x) - \left(\int x dF_n(x) \right)^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \left(\frac{1}{n} \sum_{i=1}^n X_i \right)^2.$$

- *Médiane*: $\hat{\theta} = T(F_n) = F_n^{-1}(1/2)$.

Estimation: Principe du plug-in

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Soit l'échantillon i.i.d. $\mathcal{X} = (X_1, \dots, X_n)$.

Exemples:

- *Moyenne*: $\hat{\theta} = T(F_n) = \int x dF_n(x) = \frac{1}{n} \sum_{i=1}^n X_i$.

- *Variance*:

$$\hat{\theta} = \int x^2 dF_n(x) - \left(\int x dF_n(x) \right)^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \left(\frac{1}{n} \sum_{i=1}^n X_i \right)^2.$$

- *Médiane*: $\hat{\theta} = T(F_n) = F_n^{-1}(1/2)$.

Question: Quelle est la distribution échantillonnée de l'estimateur?

$$\text{Biais}(\hat{\theta}) = E_F[\hat{\theta}] - \theta$$

$$\text{Var}(\hat{\theta}) = E_F \left[\left(\hat{\theta} - E_F[\hat{\theta}] \right)^2 \right]$$

$$\text{EQM}(\hat{\theta}) = E_F [(\hat{\theta} - \theta)^2]$$

Méthodes de Monte-Carlo

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et faiblesses

Le bootstrap en action

Exemple 1

Exemple 2

Conclusion

Supposons que F soit **connue**. Soit $S(\mathcal{X})$ une statistique.
Comment obtenir la distribution échantillonnée de S ?

Méthodes de Monte-Carlo

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithmes

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Supposons que F soit **connue**. Soit $S(\mathcal{X})$ une statistique.
Comment obtenir la distribution échantillonnée de S ?

⇒ **Monte-Carlo**: Générer B (grand!) échantillons à partir de F !

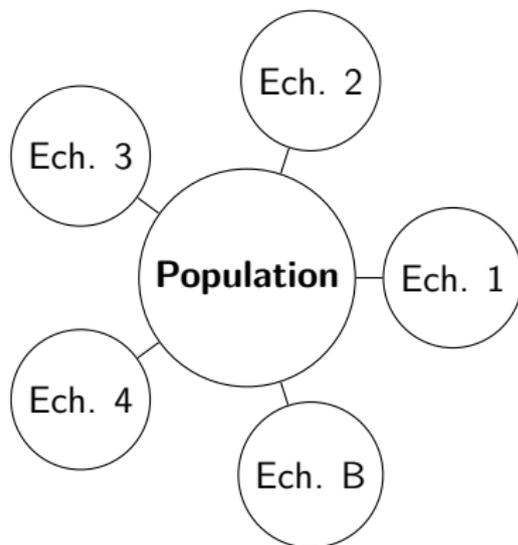


Illustration du Monte-Carlo

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Soit $X \sim \text{Exp}(\mu)$ et $\theta = \mu = E[X]$, $\hat{\theta} = S(\mathcal{X}) = \bar{X}$.

1 $\bar{X} \sim \Gamma(n, \frac{\mu}{n})$

$$H_n(x) = P[\bar{X} \leq x] = \int_0^x \frac{u^{n-1} e^{-nu/\mu}}{(\mu/n)^n \Gamma(n)} du$$

2 Pour n grand, $\bar{X} \approx \mathcal{N}(\mu, \mu^2/n)$

$$H_n(x) = P[\bar{X} \leq x] \approx \Phi\left(\frac{x - \mu}{\mu/\sqrt{n}}\right)$$

Illustration du Monte-Carlo

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Soit $X \sim \text{Exp}(\mu)$ et $\theta = \mu = E[X]$, $\hat{\theta} = S(\mathcal{X}) = \bar{X}$.

1 $\bar{X} \sim \Gamma(n, \frac{\mu}{n})$

$$H_n(x) = P[\bar{X} \leq x] = \int_0^x \frac{u^{n-1} e^{-nu/\mu}}{(\mu/n)^n \Gamma(n)} du$$

2 Pour n grand, $\bar{X} \approx \mathcal{N}(\mu, \mu^2/n)$

$$H_n(x) = P[\bar{X} \leq x] \approx \Phi\left(\frac{x - \mu}{\mu/\sqrt{n}}\right)$$

3 Simulations de Monte-Carlo

- Tirer B échantillons de F (de taille n): $\{\mathcal{X}^{(b)}, b = 1, \dots, B\}$.
- Calculer la statistique de test S pour chacun de ces échantillons.
- Approximation numérique de $H_n(x)$:

$$H_n(x) = P[\bar{X} \leq x] \approx \frac{1}{B} \sum_{b=1}^B \mathbb{1}(S(\mathcal{X}^{(b)}) \leq x)$$

Illustration du Monte-Carlo

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

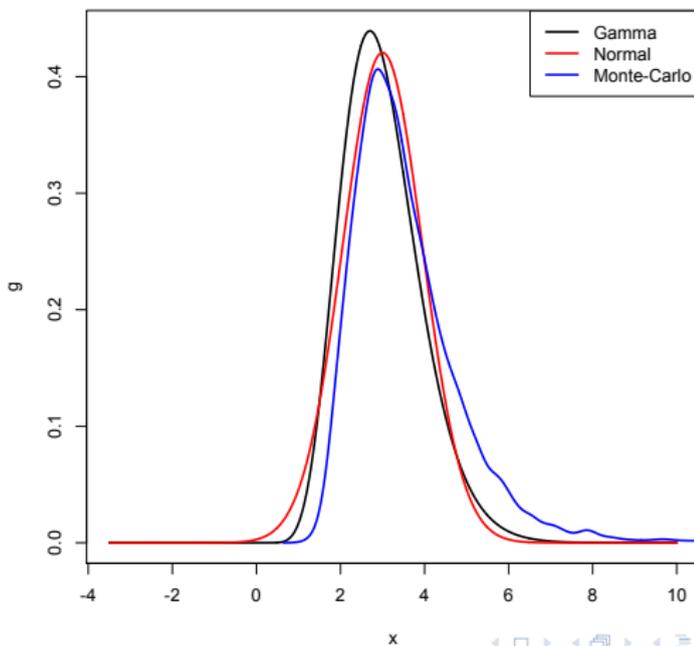
Forces et
faiblessesLe bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Distribution échantillonnée de \bar{X} pour $X \sim \text{Exp}(3)$ avec $n = 10$.



Agenda

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et faiblesses

Le bootstrap en action

Exemple 1

Exemple 2

Conclusion

1 Introduction

2 Le bootstrap

3 Algorithme

4 Forces et faiblesses

5 Le bootstrap en action

6 Conclusion

Deux mondes parallèles

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblessesLe bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Monde réel

$$\begin{array}{ccc}
 F & \longrightarrow & F_n \\
 T \downarrow & & \downarrow T \\
 \theta & \longleftrightarrow & \hat{\theta}_n
 \end{array}$$

$\mathcal{X} = (X_1, X_2, \dots, X_n)$ issu d'une population dont F est **inconnue**.

- $T(F_n)$ est un estimateur de θ .
- Distribution de $T(F_n)$ (ou $S(\mathcal{X})$) autour de θ inconnue.

Deux mondes parallèles

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et faiblesses

Le bootstrap en action

Exemple 1

Exemple 2

Conclusion

Monde réel

$$\begin{array}{ccc} F & \longrightarrow & F_n \\ T \downarrow & & \downarrow T \\ \theta & \longleftrightarrow & \hat{\theta}_n \end{array}$$

$\mathcal{X} = (X_1, X_2, \dots, X_n)$ issu d'une population dont F est **inconnue**.

- $T(F_n)$ est un estimateur de θ .
- Distribution de $T(F_n)$ (ou $S(\mathcal{X})$) autour de θ inconnue.

Monde du bootstrap

$$\begin{array}{ccc} F_n & \longrightarrow & F_n^R \\ T \downarrow & & \downarrow T \\ \hat{\theta}_n & \longleftrightarrow & \hat{\theta}_n^{*R} \end{array}$$

$\mathcal{X}^* = (X_1^*, X_2^*, \dots, X_n^*)$ issu de la population \mathcal{X} dont F_n est **connue**.

- $T(F_n^R)$ (ou $S(\mathcal{X}^*)$) est un estimateur de $\hat{\theta}$.
- **Conditionnellement** à \mathcal{X} , la distribution de $S(\mathcal{X}^*)$ est connue!

Deux mondes parallèles

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Monde réel

$$\begin{array}{ccc} F & \longrightarrow & F_n \\ T \downarrow & & \downarrow T \\ \theta & \longleftrightarrow & \hat{\theta}_n \end{array}$$

$\mathcal{X} = (X_1, X_2, \dots, X_n)$ issu d'une population dont F est **inconnue**.

- $T(F_n)$ est un estimateur de θ .
- Distribution de $T(F_n)$ (ou $S(\mathcal{X})$) autour de θ inconnue.

Monde du bootstrap

$$\begin{array}{ccc} F_n & \longrightarrow & F_n^R \\ T \downarrow & & \downarrow T \\ \hat{\theta}_n & \longleftrightarrow & \hat{\theta}_n^{*R} \end{array}$$

$\mathcal{X}^* = (X_1^*, X_2^*, \dots, X_n^*)$ issu de la population \mathcal{X} dont F_n est **connue**.

- $T(F_n^R)$ (ou $S(\mathcal{X}^*)$) est un estimateur de $\hat{\theta}$.
- **Conditionnellement** à \mathcal{X} , la distribution de $S(\mathcal{X}^*)$ est connue!

Principe: Distribution de $S(\mathcal{X}) \approx$ Distribution de $S(\mathcal{X}^*)$

Le principe du Bootstrap

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et faiblesses

Le bootstrap en action

Exemple 1

Exemple 2

Conclusion

L'échantillon bootstrap est à l'échantillon ce que l'échantillon est à la population!

Le principe du Bootstrap

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblessesLe bootstrap en
action

Exemple 1

Exemple 2

Conclusion

L'échantillon bootstrap est à l'échantillon ce que l'échantillon est à la population!

Dans le **monde du bootstrap**:

$$\text{Distribution: } F_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}(X_i \leq x)$$

$$\text{Paramètre d'intérêt: } \hat{\theta} = S(\mathcal{X}).$$

Echantillon bootstrap \mathcal{X}^* issu de F_n .

Estimateur échantillon bootstrap : $\hat{\theta}_n^* = S(\mathcal{X}^*)$.

Principe:

Distribution échantillonnée de $\hat{\theta}_n$ autour de $\theta \approx$ Distribution échantillonnée de $\hat{\theta}_n^*$ autour de $\hat{\theta}$.

Le monde du Bootstrap

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Question: Comment construire la distribution échantillonnée de $\hat{\theta}_n^*$?

Le monde du Bootstrap

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblessesLe bootstrap en
action

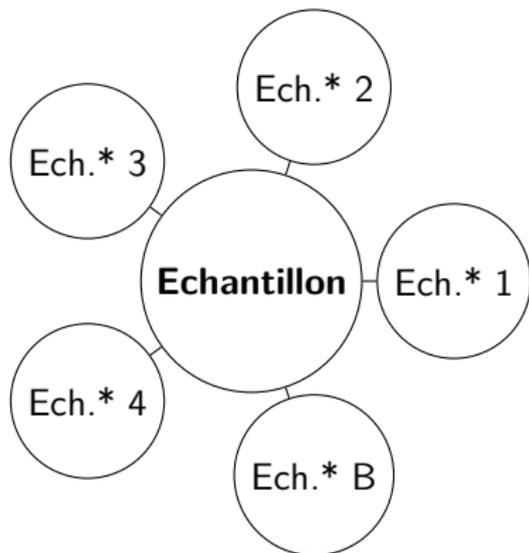
Exemple 1

Exemple 2

Conclusion

Question: Comment construire la distribution échantillonnée de $\hat{\theta}_n^*$?
 \implies via Monte-Carlo (rééchantillonnage):

- 1 Bootstrap non-paramétrique
- 2 Bootstrap paramétrique



L'idée du rééchantillonnage (*Efron, 1979*)

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblesses

Le bootstrap en
action

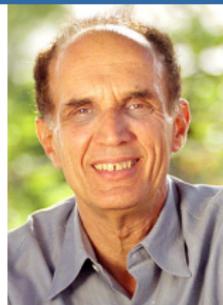
Exemple 1

Exemple 2

Conclusion

L'idée se base sur la technique de rééchantillonnage **avec remplacement**.

Qu'est ce qu'un rééchantillonnage?



L'idée du rééchantillonnage (Efron, 1979)

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblessesLe bootstrap en
action

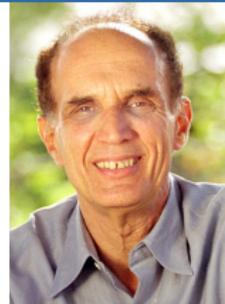
Exemple 1

Exemple 2

Conclusion

L'idée se base sur la technique de rééchantillonnage **avec remplacement**.

Qu'est ce qu'un rééchantillonnage?



Soit l'échantillon $\mathcal{X} = (2, 12, 20, 26, 78)$ de taille $n = 5$.

$$\left\{ \begin{array}{l} \mathcal{X}^{*(1)} = (12, 20, 78, 26, 2) \\ \mathcal{X}^{*(2)} = (26, 78, 12, 12, 2) \\ \mathcal{X}^{*(3)} = (20, 20, 20, 20, 20) \\ \dots \\ \mathcal{X}^{*(B)} = (26, 2, 2, 78, 20) \end{array} \right.$$

Principe du bootstrap: exemple

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en
action

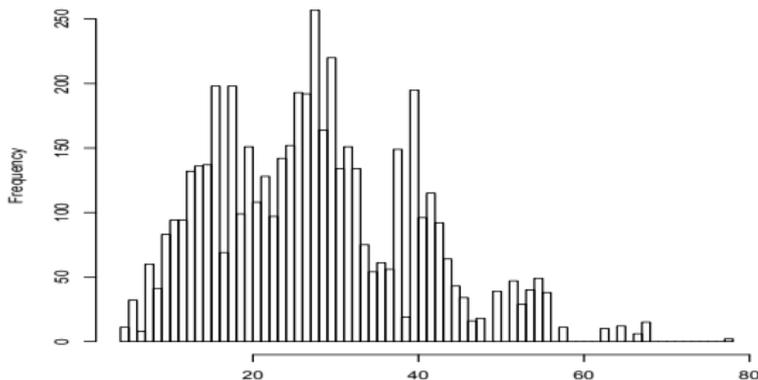
Exemple 1

Exemple 2

Conclusion

Soit l'échantillon $\mathcal{X} = (2, 12, 20, 26, 78)$ et $S(\mathcal{X}) = \bar{X}$.

$$\left\{ \begin{array}{l} \mathcal{X}^{*(1)} = (12, 20, 78, 26, 2) \longrightarrow S(\mathcal{X}^*) = 27.6 \\ \mathcal{X}^{*(2)} = (26, 78, 12, 12, 2) \longrightarrow S(\mathcal{X}^*) = 26 \\ \mathcal{X}^{*(3)} = (20, 20, 20, 20, 20) \longrightarrow S(\mathcal{X}^*) = 20 \\ \vdots \quad \vdots \quad \vdots \quad \vdots \quad \vdots \quad \vdots \quad \vdots \\ \mathcal{X}^{*(B)} = (26, 20, 12, 2, 26) \longrightarrow S(\mathcal{X}^*) = 17.2 \end{array} \right.$$



Inférence sur le paramètre d'intérêt

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en

action

Exemple 1

Exemple 2

Conclusion

Supposons $R_n = \sqrt{n}(\hat{\theta} - \theta)$ et sa distribution $H_n(x) = P(R_n \leq x)$.

- Si H_n est **connue**,

$$IC(1 - \alpha) = \left[\hat{\theta} - \frac{q_{1-\alpha/2}}{\sqrt{n}}, \hat{\theta} - \frac{q_{\alpha/2}}{\sqrt{n}} \right]$$

où $q_{\alpha/2} = H_n^{-1}(\alpha/2)$ et $q_{1-\alpha/2} = H_n^{-1}(1 - \alpha/2)$.

Exemple: Si $X \sim \mathcal{N}(\mu, \sigma^2)$; $R_n = \sqrt{n}(\bar{X} - \mu) \sim \mathcal{N}(0, \sigma^2)$

$$IC(1 - \alpha) = \left[\bar{X} - z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right]$$

Inférence sur le paramètre d'intérêt

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Supposons $R_n = \sqrt{n}(\hat{\theta} - \theta)$ et sa distribution $H_n(x) = P(R_n \leq x)$.

- Si H_n est **connue**,

$$IC(1 - \alpha) = \left[\hat{\theta} - \frac{q_{1-\alpha/2}}{\sqrt{n}}, \hat{\theta} - \frac{q_{\alpha/2}}{\sqrt{n}} \right]$$

où $q_{\alpha/2} = H_n^{-1}(\alpha/2)$ et $q_{1-\alpha/2} = H_n^{-1}(1 - \alpha/2)$.

Exemple: Si $X \sim \mathcal{N}(\mu, \sigma^2)$; $R_n = \sqrt{n}(\bar{X} - \mu) \sim \mathcal{N}(0, \sigma^2)$

$$IC(1 - \alpha) = \left[\bar{X} - z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right]$$

- Si H_n est **inconnue**, le **bootstrap** approxime H_n !
Quantiles $q_{\alpha/2}^* = \hat{H}_n^{-1}(\alpha/2)$ et $q_{1-\alpha/2}^* = \hat{H}_n^{-1}(1 - \alpha/2)$ où:

$$\hat{H}_n(x) \approx \frac{1}{B} \sum_{b=1}^B \mathbb{1} \left(\sqrt{n}(\hat{\theta}^{*(b)} - \hat{\theta}) \leq x \right)$$

Un peu d'histoire...

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Baron Münchhausen: militaire allemand (1720-1797).

Origine: Provient des histoires à dormir debout du Baron Münchhausen. Il prétend que son cheval et lui se soient sortis d'un marécage simplement en tirant sur:

Un peu d'histoire...

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Baron Münchhausen: militaire allemand (1720-1797).

Origine: Provient des histoires à dormir debout du Baron Münchhausen. Il prétend que son cheval et lui se soient sortis d'un marécage simplement en tirant sur:

- 1 ses cheveux
- 2 les lanières de ses bottes (bootstrap)

“to pull oneself up by one's own bootstraps”

⇒ Analogie avec le problème statistique:

on se débrouille **uniquement** avec l'échantillon!

Un peu d'histoire...

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion



Figure: Baron Münchhausen (1720-1797)

Agenda

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et faiblesses

Le bootstrap en action

Exemple 1

Exemple 2

Conclusion

1 Introduction

2 Le bootstrap

3 Algorithme

4 Forces et faiblesses

5 Le bootstrap en action

6 Conclusion

De quoi a-t-on besoin pour “bootstrapper”?

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et faiblesses

Le bootstrap en action

Exemple 1

Exemple 2

Conclusion

“Dans le bootstrap, on a besoin de rien...”

...sauf peut-être...

De quoi a-t-on besoin pour “bootstrapper”?

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et faiblesses

Le bootstrap en action

Exemple 1

Exemple 2

Conclusion

“Dans le bootstrap, on a besoin de rien...”



...sauf peut-être...

Sources de variations dans le bootstrap:

- 1 échantillon original aléatoire
 \Rightarrow Approximation de $H_n(x)$ par $\hat{H}_n(x)$.
- 2 tirage aléatoire des échantillons bootstrap
 \Rightarrow Approximation de $\hat{H}_n(x)$ via Monte-Carlo (contrôle sur $B!$)

Bootstrap non paramétrique

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

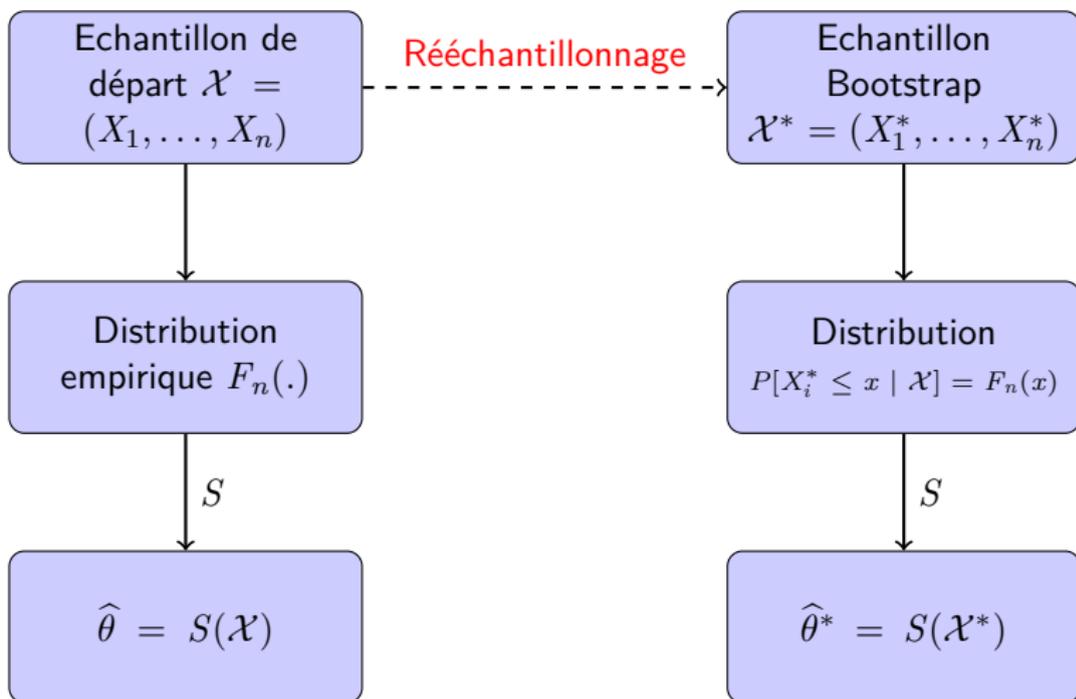
faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion



Bootstrap non paramétrique: exemple

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et faiblesses

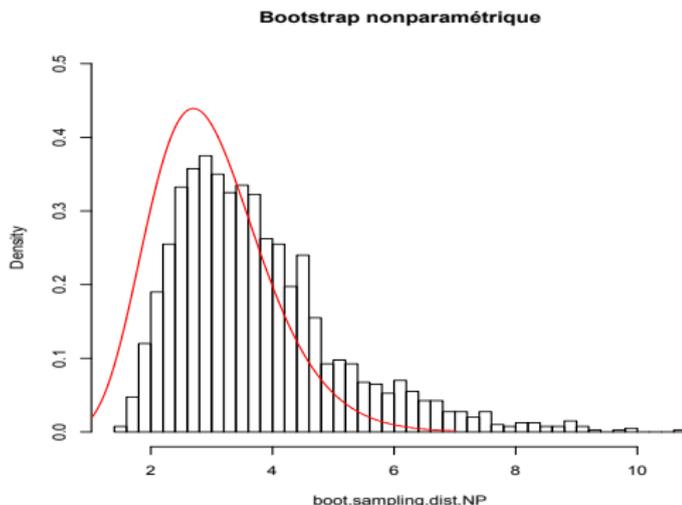
Le bootstrap en action

Exemple 1

Exemple 2

Conclusion

Soit l'échantillon (1.7, 2, 2.4, 3.9, 4.3, 4.5, 5.2, 5.8, 6.2, 7.4); $n = 10$.
 Soit $S(\mathcal{X}) = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$.



Distribution exacte: $\bar{X} \sim \Gamma(n, \frac{\mu}{n}); \quad (X \sim \text{Exp}(\mu)).$

Bootstrap paramétrique

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

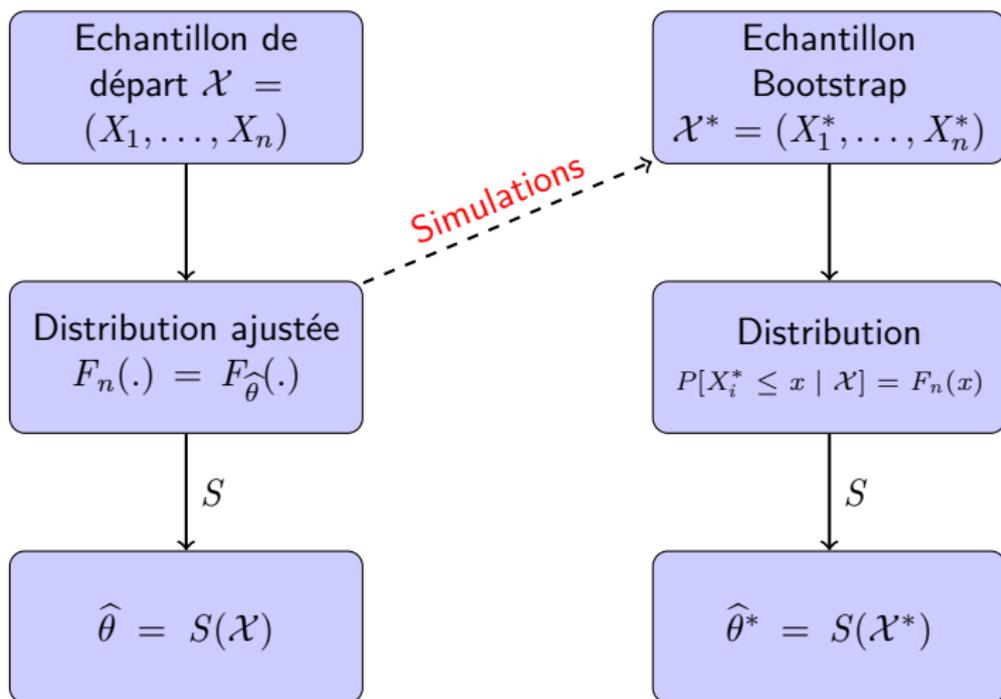
Paramétrique

Forces et
faiblessesLe bootstrap en
action

Exemple 1

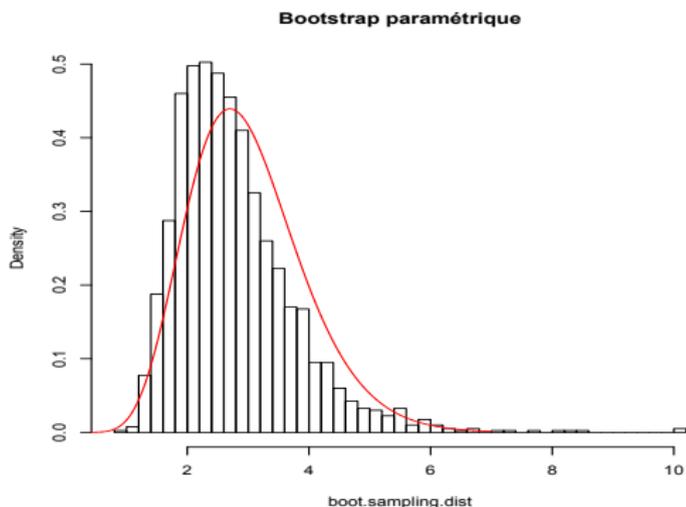
Exemple 2

Conclusion



Bootstrap paramétrique: exemple

Soit l'échantillon $(1.2, 1.7, 1.8, 2, 2.3, 2.6, 3.9, 4.3, 4.5, 5.8)$; $n = 10$.
 Simuler $B = 5000$ échantillons de la distribution $Exp(\bar{x})$.



Distribution exacte: $\bar{X} \sim \Gamma(n, \frac{\mu}{n})$; $(X \sim Exp(\mu))$.

Algorithme du bootstrap

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Soit l'échantillon $\mathcal{X} = (X_1, \dots, X_n)$.

1 Générer un échantillon bootstrap $\mathcal{X}^* = (X_1^*, \dots, X_n^*)$:

- Paramétrique
- Non-paramétrique

2 Calculer $S^* = S(X_1^*, \dots, X_n^*) = \hat{\theta}^*$.

3 Répéter les étapes 1 et 2 un certain nombre de fois B .

4 Approximer $H_n(x)$ par

$$\hat{H}_n(x) = \frac{1}{B} \sum_{j=1}^B \mathbb{1} \left(\sqrt{n}(\hat{\theta}_j^* - \hat{\theta}) \leq x \right).$$

5 Trouver les quantiles $\hat{q}_{\alpha/2}$ et $\hat{q}_{1-\alpha/2}$ de $\hat{H}_n(x)$ et construire l'IC.

Agenda

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et faiblesses

Le bootstrap en action

Exemple 1

Exemple 2

Conclusion

1 Introduction

2 Le bootstrap

3 Algorithme

4 Forces et faiblesses

5 Le bootstrap en action

6 Conclusion

Le bootstrap: une panacée pour l'inférence?

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en action

Exemple 1

Exemple 2

Conclusion

Forces:

- Permet de calculer des intervalles de confiance, de corriger pour le biais et d'estimer la variabilité liée à l'estimation.
- Peut être une solution pour des problèmes compliqués.
- Même si les résultats asymptotiques sont disponibles, le bootstrap offre souvent de meilleures approximations.
- Facile à implémenter.
- Flexible.

Faiblesses:

- Ne marche pas toujours!
- Peut être lourd computationnellement.
- Dépend de la représentativité de l'échantillon de départ.

Agenda

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et faiblesses

Le bootstrap en action

Exemple 1

Exemple 2

Conclusion

1 Introduction

2 Le bootstrap

3 Algorithme

4 Forces et faiblesses

5 Le bootstrap en action

6 Conclusion

Exemple 1: Régression linéaire (1)

Modèle: $y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$, $i = 1, \dots, n$; $\varepsilon_i \sim \mathcal{N}(0, \sigma^2)$.

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Exemple 1: Régression linéaire (1)

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblessesLe bootstrap en
action

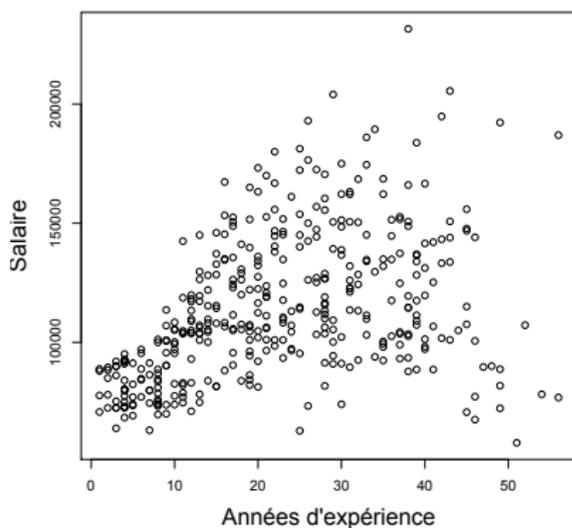
Exemple 1

Exemple 2

Conclusion

Modèle: $y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$, $i = 1, \dots, n$; $\varepsilon_i \sim \mathcal{N}(0, \sigma^2)$.

Données: Salaires de 397 professeurs dans un "American College" (2008-2009).



Exemple 1: Régression linéaire (1)

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblessesLe bootstrap en
action

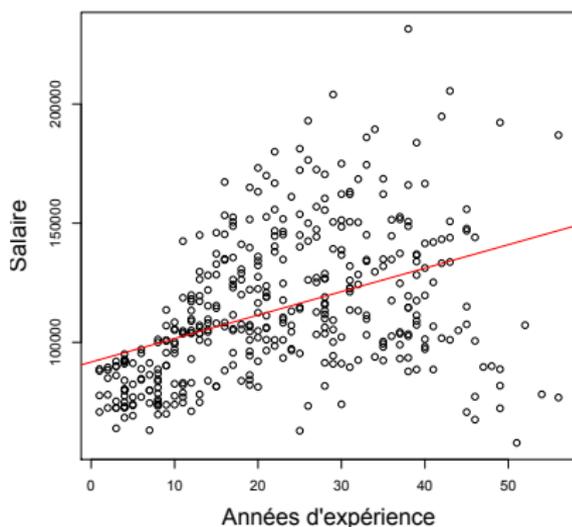
Exemple 1

Exemple 2

Conclusion

Modèle: $y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$, $i = 1, \dots, n$; $\varepsilon_i \sim \mathcal{N}(0, \sigma^2)$.

Données: Salaires de 397 professeurs dans un "American College" (2008-2009).



Exemple 1: Régression linéaire (2)

$$\text{Inférence: } \frac{\hat{\beta}_0 - \beta_0}{SE(\hat{\beta}_0)} \sim t_{n-1} \quad \text{et} \quad \frac{\hat{\beta}_1 - \beta_1}{SE(\hat{\beta}_1)} \sim t_{n-1}.$$

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Exemple 1: Régression linéaire (2)

$$\text{Inférence: } \frac{\widehat{\beta}_0 - \beta_0}{SE(\widehat{\beta}_0)} \sim t_{n-1} \quad \text{et} \quad \frac{\widehat{\beta}_1 - \beta_1}{SE(\widehat{\beta}_1)} \sim t_{n-1}.$$

Possibilités de rééchantillonnage:

- 1 couples $\{(x_i, y_i), i = 1, \dots, n\}$
- 2 résidus $\{r_i = y_i - \widehat{y}_i, i = 1, \dots, n\}$

	β_0		β_1	
	Est.	SE	Est.	SE
Théorie	91718.7	2765.8	985.3	107.4
Bootstrap	91718.6	2454.1	985.3	126

	β_0	β_1
	IC(95%)	IC(95%)
Théorie	[86281, 97156]	[774, 1196]
Bootstrap	[87315, 97726]	[702, 1225]

Exemple 2: estimation d'une frontière (1)

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en

action

Exemple 1

Exemple 2

Conclusion

Contexte: $X \sim U[0, \theta]$ et $\mathcal{X} = (X_1, X_2, \dots, X_n)$.

$$\hat{\theta}_{MV} = \max(X_1, X_2, \dots, X_n)$$

Exemple 2: estimation d'une frontière (1)

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithmes

Non Paramétrique

Paramétrique

Forces et
faiblessesLe bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Contexte: $X \sim U[0, \theta]$ et $\mathcal{X} = (X_1, X_2, \dots, X_n)$.

$$\hat{\theta}_{MV} = \max(X_1, X_2, \dots, X_n)$$

Monde réel:

$$R_n(\theta) = \frac{n(\theta - \hat{\theta})}{\theta} \sim \text{Exp}(\cdot)$$

Monde du bootstrap:

$$R_n^*(\hat{\theta}) = \frac{n(\hat{\theta} - \hat{\theta}^*)}{\hat{\theta}}$$

$$P[R_n^*(\hat{\theta}) = 0 \mid \mathcal{X}] = 1 - \left(1 - \frac{1}{n}\right)^n \longrightarrow 1 - e^{-1} \quad \text{pour } n \rightarrow \infty.$$

Problème: le maximum est tiré trop souvent dans le monde du bootstrap.

Exemple 2: estimation d'une frontière (2)

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et
faiblessesLe bootstrap en
action

Exemple 1

Exemple 2

Conclusion

Contexte: $X \sim U[0, \theta]$ et $\mathcal{X} = (X_1, X_2, \dots, X_n)$.

Solution: sous-échantillonnage (“subsampling”)

Monde réel:

$$R_n(\theta) = \frac{n(\theta - \hat{\theta})}{\theta} \sim \text{Exp}(\cdot)$$

Monde du bootstrap:

$$R_n^*(\hat{\theta}) = \frac{n(\hat{\theta} - \hat{\theta}^*)}{\hat{\theta}}$$

$P[R_n^*(\hat{\theta}) = 0 \mid \mathcal{X}] = 1 - \left(1 - \frac{1}{n}\right)^m \rightarrow 0$ pour $n \rightarrow \infty$, et $\frac{m}{n} \rightarrow 0$,
et où m est la taille du sous-échantillon.

Agenda

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et faiblesses

Le bootstrap en action

Exemple 1

Exemple 2

Conclusion

1 Introduction

2 Le bootstrap

3 Algorithme

4 Forces et faiblesses

5 Le bootstrap en action

6 Conclusion

Conclusion

- Le bootstrap est une technique prometteuse fortement utilisée (l'usage computationnel s'améliore).
- ⚠ à ne pas banaliser l'usage du bootstrap.
- Le bootstrap en pratique:
 - 1 **R cran**: package *boot* et *bootstrap*
 - 2 **Matlab**: bootstrap toolbox
- Extensions possibles:
 - Subsampling
 - Smooth bootstrap
 - Block bootstrap (séries temporelles)
 - Jackknife
 - Iterated bootstrap
 - ...

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et

faiblesses

Le bootstrap en
action

Exemple 1

Exemple 2

Conclusion

La conclusion de John Tukey

Introduction

La statistique

Pré-requis

Monte-Carlo

Le bootstrap

Principe

Historique

Algorithme

Non Paramétrique

Paramétrique

Forces et faiblesses

Le bootstrap en action

Exemple 1

Exemple 2

Conclusion



“The bootstrap is like a **shotgun** because you can blow the head off any statistical problem...”

Quelques références

Introduction

La statistique

Pré-requis
Monte-Carlo

Le bootstrap

Principe
Historique

Algorithme

Non Paramétrique
Paramétrique

Forces et faiblesses

Le bootstrap en action

Exemple 1
Exemple 2

Conclusion



P. Bickel and D. Freeman (1981) *Some asymptotic theory for the bootstrap*, *Annals of Statistics*, 9:1196-1217.



A.C. Davison and D.V. Hinkley (1997) *Bootstrap methods and their Application*, *Cambridge University Press*.



B. Efron (1979) *Bootstrap methods: Another look at the jackknife*, *Annals of Statistics*, 7:1-26.



B. Efron and R.J. Tibshirani (1993) *An introduction to the bootstrap*, *Chapman and Hall*, New York.



P. Hall (1992) *The bootstrap and Edgeworth Expansion*, *Springer-Verlag*, New York.



J.L. Horowitz (2000) *The bootstrap*.



L. Simar (2008) *An invitation to the bootstrap: Panacea for Statistical Inference?*