

Bootstrap

Master parcours SSD - UE Statistique Computationnelle

Pierre Mahé - bioMérieux & Université de Grenoble-Alpes

- ▶ **Bootstrap** : méthode d'inférence basée sur le **ré-échantillonnage** d'un échantillon.
- ▶ Approche **non-paramétrique** : pas d'hypothèse sur la loi de la variable aléatoire sous-jacente.
- ▶ Principe générique décliné pour **différentes applications**.

- ▶ Introduction
- ▶ Formalisation du principe de **ré-échantillonnage**
- ▶ Le bootstrap pour l'**inférence statistique** :
 - ▶ caractérisation d'un estimateur
 - ▶ intervalles de confiance
- ▶ **2 applications** classiques :
 - ▶ régression
 - ▶ construction de modèles de prédiction
- ▶ Conclusion

Introduction

Cours précédent :

- ▶ méthodes de **simulation** pour répondre à des questions d'**inférence statistique**.
- ▶ données simulées selon des **modèles paramétriques**.

Cours précédent :

- ▶ méthodes de **simulation** pour répondre à des questions d'**inférence statistique**.
- ▶ données simulées selon des **modèles paramétriques**.

Le bootstrap :

- ▶ même objectif mais vise à **relâcher ces hypothèses**.
- ▶ se base uniquement sur le vecteur d'observations disponibles : **ré-échantillonnage**.

⇒ une approche totalement **non paramétrique**

Le bootstrap en deux mots

On s'intéresse à un estimateur $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$ d'un paramètre θ .

Le bootstrap en deux mots

On s'intéresse à un estimateur $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$ d'un paramètre θ .

On veut caractériser sa distribution d'échantillonnage, **en se basant uniquement sur l'échantillon (X_1, \dots, X_n)** .

Le bootstrap en deux mots

On s'intéresse à un estimateur $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$ d'un paramètre θ .


On veut caractériser sa distribution d'échantillonnage, **en se basant uniquement sur l'échantillon (X_1, \dots, X_n)** .

On applique la procédure suivante :


- ▶ Pour b allant de 1 à B ,
- ▶ On génère un échantillon (X_1^*, \dots, X_n^*) en **tirant avec remise** dans (X_1, \dots, X_n) .
- ▶ On calcule la valeur de notre estimateur $\hat{\theta}^{*(b)}$ à partir de (X_1^*, \dots, X_n^*) .

Et on travaille sur les B réalisations $(\hat{\theta}^{*(b)})_{b=1, \dots, B}$.

Le bootstrap en deux mots



Données : origine ethnique des étudiants de Stanford



- ▶ On connaît toute la population
- ▶ Elle contient 6.4% d'étudiants afro-américains.


⇒ Question : estimer ce taux à partir d'un échantillon.

Illustration

On considère :

- ▶ des échantillons de taille 50.
- ▶ l'estimateur de la fréquence empirique.

⇒ **distribution d'échantillonnage** sur 1000 réalisations :



⇒ estimateur précis en moyenne, mais forte variance.

Introduction

Formalisation

Bootstrap pour l'inférence

Caractérisation d'un estimateur
Intervalles de confiance


Applications

Bootstrap & régression
Bootstrap & prédiction

Conclusion

Références

Sauf qu'en pratique, on n'aurait accès qu'à **une réalisation** :



Introduction

Formalisation

Bootstrap pour l'inférence

Caractérisation d'un estimateur
Intervalles de confiance


Applications

Bootstrap & régression
Bootstrap & prédiction

Conclusion

Références

Sauf qu'en pratique, on n'aurait accès qu'à **une réalisation** :



⇒ **bootstrap** : se baser uniquement sur notre échantillon :

- ▶ nombreux tirages avec remise
- ▶ distribution de la fréquence empirique "bootstrapée"

Introduction

Formalisation

Bootstrap pour
l'inférenceCaractérisation
d'un estimateur
Intervalles de
confiance


Applications

Bootstrap &
régression
Bootstrap &
prédiction


Conclusion

Références

Tirages dans la population :



Tirages dans l'échantillon :



- ▶ l'échantillon \sim une population finie
- ▶ on simule des échantillons de cette population
- ▶ on veut en tirer des conclusions sur la vraie population

Remarques :

- ▶ intérêt limité sur cet exemple, car on connaît très bien les propriétés de l'estimateur de la fréquence empirique.
- ▶ intérêt général de la démarche :
 - ▶ ne pas "se forcer" à faire d'hypothèses quand les données ne s'y prêtent pas
 - ▶ permet de considérer des statistiques plus complexes
 - ▶ dont on ne connaît pas forcément la distribution d'échantillonnage

Bootstrap, vous avez dit bootstrap ?


Terme introduit en statistique par **Bradley Efron** en 1979...

... vient de l'expression "to pull oneself up by one's bootstrap" ...

- ▶ ~ s'en sortir par soi même, grâce à ses efforts

...souvent attribuée aux aventures du **Baron de Munchausen**.

- ▶ le Baron, tombé dans un marécage, s'en extrait en se tirant lui même par ses "bootstraps"



Formalisation du principe de ré-échantillonnage

Récapitulatif

On s'intéresse à une **variable aléatoire X** .

Introduction

Formalisation

Bootstrap pour
l'inférence

Caractérisation
d'un estimateur
Intervalles de
confiance

Applications

Bootstrap &
régression
Bootstrap &
prédiction

Conclusion

Références

Récapitulatif

On s'intéresse à une **variable aléatoire** X .

Au niveau de la **population** \mathcal{X} :

- ▶ X est régie par une **distribution** P et une **fonction de répartition** F :

$$P(X \leq x) = F(x), \quad \forall x \in \mathcal{X}.$$

- ▶ $\theta = t(P)$ est un **paramètre d'intérêt**

Récapitulatif

On s'intéresse à une **variable aléatoire** X .

Au niveau de la **population** \mathcal{X} :

- ▶ X est régie par une **distribution** P et une **fonction de répartition** F :

$$P(X \leq x) = F(x), \quad \forall x \in \mathcal{X}.$$

- ▶ $\theta = t(P)$ est un **paramètre d'intérêt**

On dispose d'un **échantillon** $\mathbf{X} = (X_1, \dots, X_n)$:

- ▶ les X_i sont iid selon P
- ▶ $\hat{\theta} = s(\mathbf{X})$ est un **estimateur** de θ

Récapitulatif

On s'intéresse à une **variable aléatoire** X .

Au niveau de la **population** \mathcal{X} :

- ▶ X est régie par une **distribution** P et une **fonction de répartition** F :

$$P(X \leq x) = F(x), \quad \forall x \in \mathcal{X}.$$

- ▶ $\theta = t(P)$ est un **paramètre d'intérêt**

On dispose d'un **échantillon** $\mathbf{X} = (X_1, \dots, X_n)$:

- ▶ les X_i sont iid selon P
- ▶ $\hat{\theta} = s(\mathbf{X})$ est un **estimateur** de θ

⇒ **inférence** : tirer des conclusions sur θ à partir de $\hat{\theta}$.

⇒ nécessite la **distribution d'échantillonnage** de $\hat{\theta}$.

Récapitulatif

Question clé : estimer la distribution d'échantillonnage de $\hat{\theta}$.

Outline

UE StatComp

Introduction

Formalisation

Bootstrap pour
l'inférence

Caractérisation
d'un estimateur
Intervalle de
confiance

Applications

Bootstrap &
régression

Bootstrap &
prédiction

Conclusion

Références

Question clé : estimer la distribution d'échantillonnage de $\hat{\theta}$.

Stratégie #1 : l'estimer empiriquement à partir de plusieurs échantillons :

- ▶ on collecte plusieurs échantillons $\mathbf{X}_j = (X_{j1}, \dots, X_{jn})$
- ▶ on calcule $\hat{\theta}_j = s(\mathbf{X}_j)$
- ▶ on l'estime par la distribution des $\{\hat{\theta}_j\}$

Introduction

Formalisation

Bootstrap pour l'inférence

Caractérisation d'un estimateur
Intervalles de confiance

Applications

Bootstrap & régression
Bootstrap & prédiction

Conclusion

Références

Question clé : estimer la **distribution d'échantillonnage** de $\hat{\theta}$.

Stratégie #1 : l'estimer empiriquement à partir de **plusieurs échantillons** :

- ▶ on collecte plusieurs échantillons $\mathbf{X}_j = (X_{j1}, \dots, X_{jn})$
- ▶ on calcule $\hat{\theta}_j = s(\mathbf{X}_j)$
- ▶ on l'estime par la distribution des $\{\hat{\theta}_j\}$

Mais en pratique on ne dispose que d'un échantillon \mathbf{X} ...

Introduction

Formalisation

Bootstrap pour l'inférence

Caractérisation d'un estimateur
Intervalles de confiance

Applications

Bootstrap & régression
Bootstrap & prédiction

Conclusion

Références

Question clé : estimer la **distribution d'échantillonnage** de $\hat{\theta}$.

Stratégie #1 : l'estimer empiriquement à partir de **plusieurs échantillons** :

- ▶ on collecte plusieurs échantillons $\mathbf{X}_j = (X_{j1}, \dots, X_{jn})$
- ▶ on calcule $\hat{\theta}_j = s(\mathbf{X}_j)$
- ▶ on l'estime par la distribution des $\{\hat{\theta}_j\}$

Mais en pratique on ne dispose que d'un échantillon \mathbf{X} ...

⇒ **approche paramétrique** : faire des hypothèses sur la nature de la distribution P des données.

⇒ **approche non-paramétrique** : ré-échantillonnage dans \mathbf{X} pour estimer la distribution d'échantillonnage de $\hat{\theta}$.

Introduction

Formalisation

Bootstrap pour l'inférence

Caractérisation d'un estimateur
Intervalles de confiance

Applications

Bootstrap & régression
Bootstrap & prédiction

Conclusion

Références

Distribution empirique

Soit un échantillon $\mathbf{X} = (X_1, \dots, X_n)$.

On définit la **distribution empirique** \hat{P}_n comme :

$$\hat{P}_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}(X_i = x).$$



On définit de même la **fonction de répartition empirique** \hat{F}_n :

$$\hat{F}_n(t) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}(X_i \leq t).$$

Distribution empirique - illustration



Soit le vecteur $x = \{1, 1, 2, 3, 3, 4, 4, 4, 5, 5\}$.

⇒ distribution empirique \hat{P}_n : ⇒ répartition empirique \hat{F}_n :



Distribution empirique & ré-échantillonnage

Comment simuler un échantillon selon une **distribution empirique** ?



Introduction

Formalisation

Bootstrap pour l'inférence

Caractérisation d'un estimateur
Intervalles de confiance



Applications

Bootstrap & régression
Bootstrap & prédiction

Conclusion

Références

Comment simuler un échantillon selon une **distribution empirique** ?



⇒ il suffit de **tirer avec remise** dans l'échantillon original.

⇒ pour s'en convaincre, on peut utiliser la méthode d'inversion.

Introduction

Formalisation

Bootstrap pour l'inférence

Caractérisation d'un estimateur
Intervalles de confiance

Applications

Bootstrap & régression
Bootstrap & prédiction

Conclusion

Références

Ré-échantillonnage & bootstrap

On s'intéresse à un estimateur $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$ d'un paramètre θ .

Outline

UE StatComp

Introduction

Formalisation

Bootstrap pour l'inférence

Caractérisation d'un estimateur
Intervalles de confiance

Applications

Bootstrap & régression
Bootstrap & prédiction

Conclusion

Références

Ré-échantillonnage & bootstrap

On s'intéresse à un estimateur $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$ d'un paramètre θ .

On veut caractériser sa distribution d'échantillonnage, **en se basant uniquement sur l'échantillon (X_1, \dots, X_n)** .

On s'intéresse à un estimateur $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$ d'un paramètre θ .


On veut caractériser sa distribution d'échantillonnage, **en se basant uniquement sur l'échantillon (X_1, \dots, X_n)** .

On applique la procédure suivante :

- ▶ Pour b allant de 1 à B ,
- ▶ On génère un échantillon (X_1^*, \dots, X_n^*) en **tirant avec remise** dans (X_1, \dots, X_n) .
- ▶ On calcule la valeur de notre estimateur $\hat{\theta}^{*(b)}$ à partir de (X_1^*, \dots, X_n^*) .

Et on travaille sur les B réalisations $(\hat{\theta}^{*(b)})_{b=1, \dots, B}$.

Ré-échantillonnage & bootstrap




Monde réel et monde bootstrap

Formellement, le bootstrap considère des réalisations tirées de la distribution empirique définie par l'échantillon original.

On passe du monde réel au "monde bootstrap" :

- ▶ illustration tirée de Efron and Tibshirani (1993).



Monde réel et monde bootstrap

Monde réel vs monde bootstrap :

Outline

UE StatComp

Introduction

Formalisation

Bootstrap pour
l'inférence

Caractérisation
d'un estimateur
Intervalle de
confiance

Applications

Bootstrap &
régression
Bootstrap &
prédiction

Conclusion

Références

Monde réel et monde bootstrap

Monde réel vs monde bootstrap :

- ▶ distribution des données : P vs \hat{P}_n
 - ▶ vraie distribution P inconnue
 - ▶ distribution \hat{P}_n parfaitement connue

Introduction

Formalisation

Bootstrap pour
l'inférence

Caractérisation
d'un estimateur
Intervalle de
confiance

Applications

Bootstrap &
régression
Bootstrap &
prédiction

Conclusion

Références

Monde réel et monde bootstrap

Monde réel vs monde bootstrap :

- ▶ **distribution des données** : P vs \hat{P}_n
 - ▶ vraie distribution P inconnue
 - ▶ distribution \hat{P}_n parfaitement connue
- ▶ **échantillon** : (X_1, \dots, X_n) vs (X_1^*, \dots, X_n^*)
 - ▶ un unique échantillon $(X_1, \dots, X_n) \sim P$
 - ▶ autant d'échantillons $(X_1^*, \dots, X_n^*) \sim \hat{P}_n$ qu'on veut

Monde réel vs monde bootstrap :

- ▶ **distribution des données** : P vs \hat{P}_n
 - ▶ vraie distribution P inconnue
 - ▶ distribution \hat{P}_n parfaitement connue
- ▶ **échantillon** : (X_1, \dots, X_n) vs (X_1^*, \dots, X_n^*)
 - ▶ un unique échantillon $(X_1, \dots, X_n) \sim P$
 - ▶ autant d'échantillons $(X_1^*, \dots, X_n^*) \sim \hat{P}_n$ qu'on veut
- ▶ **paramètre** : θ vs $\hat{\theta}$ vs $\hat{\theta}^*$
 - ▶ un vrai paramètre θ inconnu
 - ▶ une estimation $\hat{\theta} = s(X_1, \dots, X_n)$ connue
 - ▶ NB : une estimation de θ
 - ▶ autant d'estimations $\hat{\theta}^* = s(X_1^*, \dots, X_n^*)$ qu'on veut
 - ▶ NB : des estimations de $\hat{\theta}$

Introduction

Formalisation

Bootstrap pour
l'inférenceCaractérisation
d'un estimateur
Intervalle de
confiance

Applications

Bootstrap &
régression
Bootstrap &
prédiction

Conclusion

Références

Monde réel et monde bootstrap

Dans le **monde bootstrap** :

- ▶ la distribution des données est \hat{P}_n
 - ▶ elle est **parfaitement connue**
 - ▶ on peut en **tirer/simuler des échantillons**
- ▶ le "vrai" paramètre de la population est $\hat{\theta}$
 - ▶ il est **parfaitement connu**
 - ▶ on peut le **comparer aux estimations** $\hat{\theta}^*$

Introduction

Formalisation

Bootstrap pour l'inférence

Caractérisation d'un estimateur
Intervalles de confiance

Applications

Bootstrap & régression
Bootstrap & prédiction

Conclusion

Références

Monde réel et monde bootstrap

Dans le **monde bootstrap** :

- ▶ la distribution des données est \hat{P}_n
 - ▶ elle est **parfaitement connue**
 - ▶ on peut en **tirer/simuler des échantillons**
- ▶ le "vrai" paramètre de la population est $\hat{\theta}$
 - ▶ il est **parfaitement connu**
 - ▶ on peut le **comparer aux estimations** $\hat{\theta}^*$

⇒ **principe du bootstrap** :

1. se placer dans le monde bootstrap
2. calculer la distribution d'échantillonnage des $\hat{\theta}^*$
3. se comparer à $\hat{\theta}$ (le "vrai" paramètre de \hat{P}_n)
4. en déduire des caractéristiques de $\hat{\theta}$ (par rapport à P).
 - ▶ e.g., biais, erreur-type et intervalle de confiance

Bootstrap et inférence statistique : caractérisation d'un estimateur

On peut par exemple appliquer le bootstrap pour :

- ▶ Estimer le **biais** d'un estimateur.
- ▶ Estimer son **erreur quadratique moyenne**.
- ▶ Estimer son **erreur type**.
- ▶ Donner un intervalle de confiance sur une estimation.

Estimer le biais d'un estimateur

Rappel : biais d'un estimateur : $\text{Biais}(\hat{\theta}) = E[\hat{\theta}] - \theta$.

Estimer le biais d'un estimateur

Rappel : biais d'un estimateur : $\text{Biais}(\hat{\theta}) = E[\hat{\theta}] - \theta$.

Procédure bootstrap :

1. On dispose d'un échantillon (X_1, \dots, X_n) .
2. On calcule $\hat{\theta}$ sur l'échantillon.
3. On applique la procédure bootstrap pour obtenir des réalisations $\hat{\theta}^{*(b)}$:
 - ▶ Pour b allant de 1 à B ,
 - ▶ on génère un échantillon (X_1^*, \dots, X_n^*) ,
 - ▶ on calcule $\hat{\theta}^{*(b)}$ à partir de (X_1^*, \dots, X_n^*) .

Estimer le biais d'un estimateur

Rappel : biais d'un estimateur : $\text{Biais}(\hat{\theta}) = E[\hat{\theta}] - \theta$.

Procédure bootstrap :

1. On dispose d'un échantillon (X_1, \dots, X_n) .
2. On calcule $\hat{\theta}$ sur l'échantillon.
3. On applique la procédure bootstrap pour obtenir des réalisations $\hat{\theta}^{*(b)}$:
 - ▶ Pour b allant de 1 à B ,
 - ▶ on génère un échantillon (X_1^*, \dots, X_n^*) ,
 - ▶ on calcule $\hat{\theta}^{*(b)}$ à partir de (X_1^*, \dots, X_n^*) .

On estime le biais de $\hat{\theta}$ par :

$$\widehat{\text{Biais}}(\hat{\theta}) = \frac{1}{B} \sum_{b=1}^B \hat{\theta}^{*(b)} - \hat{\theta}.$$

Estimer l'erreur quadratique moyenne (MSE) d'un estimateur

Rappel : MSE d'un estimateur : $MSE(\hat{\theta}) = E[(\hat{\theta} - \theta)^2]$.

Estimer l'erreur quadratique moyenne (MSE) d'un estimateur

Rappel : MSE d'un estimateur : $MSE(\hat{\theta}) = E[(\hat{\theta} - \theta)^2]$.

Procédure bootstrap :

1. On dispose d'un échantillon (X_1, \dots, X_n) .
2. On calcule $\hat{\theta}$ sur l'échantillon.
3. On applique la procédure bootstrap pour obtenir des réalisations $\hat{\theta}^{*(b)}$:
 - ▶ Pour b allant de 1 à B ,
 - ▶ on génère un échantillon (X_1^*, \dots, X_n^*) ,
 - ▶ on calcule $\hat{\theta}^{*(b)}$ à partir de (X_1^*, \dots, X_n^*) .

Introduction

Formalisation

Bootstrap pour l'inférence

Caractérisation d'un estimateur
Intervalles de confiance

Applications

Bootstrap & régression
Bootstrap & prédiction

Conclusion

Références

Estimer l'erreur quadratique moyenne (MSE) d'un estimateur

Rappel : MSE d'un estimateur : $MSE(\hat{\theta}) = E[(\hat{\theta} - \theta)^2]$.

Procédure bootstrap :

1. On dispose d'un échantillon (X_1, \dots, X_n) .
2. On calcule $\hat{\theta}$ sur l'échantillon.
3. On applique la procédure bootstrap pour obtenir des réalisations $\hat{\theta}^{*(b)}$:
 - ▶ Pour b allant de 1 à B ,
 - ▶ on génère un échantillon (X_1^*, \dots, X_n^*) ,
 - ▶ on calcule $\hat{\theta}^{*(b)}$ à partir de (X_1^*, \dots, X_n^*) .

On estime l'erreur quadratique moyenne de $\hat{\theta}$ par :

$$\widehat{MSE}(\hat{\theta}) = \frac{1}{B} \sum_{b=1}^B (\hat{\theta}^{*(b)} - \hat{\theta})^2.$$

[Introduction](#)[Formalisation](#)[Bootstrap pour l'inférence](#)[Caractérisation d'un estimateur](#)
[Intervalles de confiance](#)[Applications](#)[Bootstrap & régression](#)
[Bootstrap & prédiction](#)[Conclusion](#)[Références](#)

Estimer l'erreur type d'un estimateur

Rappel : erreur type d'un estimateur : l'écart type de sa distribution d'échantillonnage.

Estimer l'erreur type d'un estimateur

Rappel : **erreur type** d'un estimateur : l'écart type de sa distribution d'échantillonnage.

Procédure bootstrap :

1. On dispose d'un échantillon (X_1, \dots, X_n) .
2. On applique la procédure bootstrap pour obtenir des réalisations $\hat{\theta}^{*(b)}$:
 - ▶ Pour b allant de 1 à B ,
 - ▶ on génère un échantillon (X_1^*, \dots, X_n^*) ,
 - ▶ on calcule $\hat{\theta}^{*(b)}$ à partir de (X_1^*, \dots, X_n^*) .

Estimer l'erreur type d'un estimateur

Rappel : **erreur type** d'un estimateur : l'écart type de sa distribution d'échantillonnage.

Procédure bootstrap :

1. On dispose d'un échantillon (X_1, \dots, X_n) .
2. On applique la procédure bootstrap pour obtenir des réalisations $\hat{\theta}^{*(b)}$:
 - ▶ Pour b allant de 1 à B ,
 - ▶ on génère un échantillon (X_1^*, \dots, X_n^*) ,
 - ▶ on calcule $\hat{\theta}^{*(b)}$ à partir de (X_1^*, \dots, X_n^*) .

On estime l'erreur-type de $\hat{\theta}$ par l'écart-type des $(\hat{\theta}^{*(b)})$:

$$\widehat{\text{se}}(\hat{\theta}) = \sqrt{\frac{1}{B-1} \sum_{b=1}^B \left(\hat{\theta}^{*(b)} - \bar{\theta}^* \right)^2} \quad \text{où} \quad \bar{\theta}^* = \frac{1}{B} \sum_{b=1}^B \hat{\theta}^{*(b)}.$$

Remarque importante

In fine, on estime la "vraie" variance de $\hat{\theta}$ (i.e., selon P) par la variance empirique des $(\hat{\theta}^{*(b)})$ (i.e., selon \hat{P}_n).

Remarque importante

In fine, on estime la "vraie" variance de $\hat{\theta}$ (i.e., selon P) par la variance empirique des $(\hat{\theta}^{*(b)})$ (i.e., selon \hat{P}_n).

Il faut bien comprendre qu'il y a 2 niveaux d'approximation :

1. approximer la vraie distribution P par l'empirique \hat{P}_n .
2. approximer la variance de $\hat{\theta}$ selon \hat{P}_n par la variance empirique des $(\hat{\theta}^{*(b)})$.

Remarque importante

In fine, on estime la "vraie" variance de $\hat{\theta}$ (i.e., selon P) par la variance empirique des $(\hat{\theta}^{*(b)})$ (i.e., selon \hat{P}_n).

Il faut bien comprendre qu'il y a 2 niveaux d'approximation :

1. approximer la vraie distribution P par l'empirique \hat{P}_n .
2. approximer la variance de $\hat{\theta}$ selon \hat{P}_n par la variance empirique des $(\hat{\theta}^{*(b)})$.

⇒ point #2 : ok, il suffit de prendre B grand.

⇒ point #1 : plus délicat...mais valide quand n est grand.

Remarque importante

In fine, on estime la "vraie" variance de $\hat{\theta}$ (i.e., selon P) par la variance empirique des $(\hat{\theta}^{*(b)})$ (i.e., selon \hat{P}_n).

Il faut bien comprendre qu'il y a 2 niveaux d'approximation :

1. approximer la vraie distribution P par l'empirique \hat{P}_n .
2. approximer la variance de $\hat{\theta}$ selon \hat{P}_n par la variance empirique des $(\hat{\theta}^{*(b)})$.

⇒ point #2 : ok, il suffit de prendre B grand.

⇒ point #1 : plus délicat...mais valide quand n est grand.

⚠ bootstrap \neq méthode pour petits échantillons !

- ▶ intérêt #1 = relâcher hypothèses paramétriques
- ▶ intérêt #2 = générique, valable pour toute statistique

Calcul du biais et de l'erreur type de la moyenne :

```
> x = c(1,1,2,3,3,4,4,4,5,5)
> n = length(x)
> B = 2000
> theta.hat = mean(x)
> theta.b = numeric(B)
> for(b in 1:B){
ind = sample(1:n, size = n, replace = TRUE)
theta.b[b] = mean(x[ind])
}
> bias = mean(theta.b) - theta.hat
> se = sd(theta.b)
```

Bootstrap et inférence statistique : intervalles de confiance

Il existe de **nombreuses manières** de définir des intervalles de confiance par bootstrap.

Il existe de **nombreuses manières** de définir des intervalles de confiance par bootstrap.

Nous allons considérer deux définitions se basant uniquement sur les quantiles de la distribution des $\hat{\theta}^{*(b)}$:

- ▶ l'intervalle de confiance **des percentiles**.
- ▶ l'intervalle de confiance **basique** (ou "du pivot").

Ces définitions font le moins d'hypothèses possible.

Intervalle de confiance - méthode des percentiles

Cette définition est probablement la plus simple et intuitive.


Elle consiste à calculer empiriquement l'**intervalle couvrant** $100(1 - \alpha)\%$ des estimations bootstrap obtenues.

Formellement, en notant q_α^* le **quantile d'ordre α de la distribution des estimations bootstrap $\hat{\theta}^{*(b)}$** , il est défini comme :

$$[q_{\alpha/2}^* ; q_{1-\alpha/2}^*].$$

Intervalle de confiance - méthode basique (1/3)

On va s'intéresser à la distribution de la **statistique** $(\hat{\theta} - \theta)$:



Si a_α le quantile d'ordre α de la statistique $(\hat{\theta} - \theta)$ alors :

$$P(\hat{\theta} - \theta \leq a_\alpha) = \alpha \text{ et } P(\hat{\theta} - \theta \geq a_{1-\alpha}) = \alpha.$$

Intervalle de confiance - méthode basique (2/3)

On a donc (par définition) :

$$P(\hat{\theta} - \theta \leq a_\alpha) = \alpha \text{ et } P(\hat{\theta} - \theta \geq a_{1-\alpha}) = \alpha,$$

où a_α le quantile d'ordre α de la statistique $(\hat{\theta} - \theta)$.

Intervalle de confiance - méthode basique (2/3)

On a donc (par définition) :

$$P(\hat{\theta} - \theta \leq a_\alpha) = \alpha \text{ et } P(\hat{\theta} - \theta \geq a_{1-\alpha}) = \alpha,$$

où a_α le quantile d'ordre α de la statistique $(\hat{\theta} - \theta)$.

\Rightarrow on peut écrire :

$$P(\theta \geq \hat{\theta} - a_\alpha) = \alpha \text{ et } P(\theta \leq \hat{\theta} - a_{1-\alpha}) = \alpha,$$

Intervalle de confiance - méthode basique (2/3)

On a donc (par définition) :

$$P(\hat{\theta} - \theta \leq a_{\alpha}) = \alpha \text{ et } P(\hat{\theta} - \theta \geq a_{1-\alpha}) = \alpha,$$

où a_{α} le quantile d'ordre α de la statistique $(\hat{\theta} - \theta)$.

⇒ on peut écrire :

$$P(\theta \geq \hat{\theta} - a_{\alpha}) = \alpha \text{ et } P(\theta \leq \hat{\theta} - a_{1-\alpha}) = \alpha,$$

et en déduire l'**intervalle de confiance** à $100(1 - \alpha)\%$:

$$[\hat{\theta} - a_{1-\alpha/2} ; \hat{\theta} - a_{\alpha/2}].$$

Intervalle de confiance - méthode basique (3/3)

On considère donc l'intervalle de confiance défini comme

$$[\hat{\theta} - a_{1-\alpha/2} ; \hat{\theta} - a_{\alpha/2}],$$

où a_α le quantile d'ordre α de la statistique $(\hat{\theta} - \theta)$.

Intervalle de confiance - méthode basique (3/3)

On considère donc l'intervalle de confiance défini comme

$$[\hat{\theta} - a_{1-\alpha/2} ; \hat{\theta} - a_{\alpha/2}],$$

où a_α le quantile d'ordre α de la statistique $(\hat{\theta} - \theta)$.

Problème : on ne connaît pas la distribution de $(\hat{\theta} - \theta)$.

Intervalle de confiance - méthode basique (3/3)

On considère donc l'intervalle de confiance défini comme

$$[\hat{\theta} - a_{1-\alpha/2} ; \hat{\theta} - a_{\alpha/2}],$$

où a_α le quantile d'ordre α de la statistique $(\hat{\theta} - \theta)$.

Problème : on ne connaît pas la distribution de $(\hat{\theta} - \theta)$.

⇒ On passe dans le **monde bootstrap** : on approxime la distribution de $(\hat{\theta} - \theta)$ par celle de $(\hat{\theta}^{*(b)} - \hat{\theta})$.

Intervalle de confiance - méthode basique (3/3)

On considère donc l'intervalle de confiance défini comme

$$[\hat{\theta} - a_{1-\alpha/2} ; \hat{\theta} - a_{\alpha/2}],$$

où a_α le quantile d'ordre α de la statistique $(\hat{\theta} - \theta)$.

Problème : on ne connaît pas la distribution de $(\hat{\theta} - \theta)$.

⇒ On passe dans le **monde bootstrap** : on approxime la distribution de $(\hat{\theta} - \theta)$ par celle de $(\hat{\theta}^{*(b)} - \hat{\theta})$.

► on peut donc écrire :

$$a_\alpha = q_\alpha^* - \hat{\theta}, \text{ où } q_\alpha^* \text{ est le quantile d'ordre } \alpha \text{ des } \hat{\theta}^{*(b)}.$$

Intervalle de confiance - méthode basique (3/3)

On considère donc l'intervalle de confiance défini comme

$$[\hat{\theta} - a_{1-\alpha/2} ; \hat{\theta} - a_{\alpha/2}],$$

où a_α le quantile d'ordre α de la statistique $(\hat{\theta} - \theta)$.

Problème : on ne connaît pas la distribution de $(\hat{\theta} - \theta)$.

⇒ On passe dans le **monde bootstrap** : on approxime la distribution de $(\hat{\theta} - \theta)$ par celle de $(\hat{\theta}^{*(b)} - \hat{\theta})$.

▶ on peut donc écrire :

$$a_\alpha = q_\alpha^* - \hat{\theta}, \text{ où } q_\alpha^* \text{ est le quantile d'ordre } \alpha \text{ des } \hat{\theta}^{*(b)}.$$

▶ on en déduit la définition suivante :

$$[2\hat{\theta} - q_{1-\alpha/2}^* ; 2\hat{\theta} - q_{\alpha/2}^*].$$

Bootstrap & intervalles de confiance - remarques

Deux définitions considérées :

1. IC des percentiles : $[q_{\alpha/2}^* ; q_{1-\alpha/2}^*]$.
2. IC basique : $[2\hat{\theta} - q_{1-\alpha/2}^* ; 2\hat{\theta} - q_{\alpha/2}^*]$.

⇒ se basent uniquement sur q_{α}^* : le quantile d'ordre α des estimations bootstrap $\hat{\theta}^{*(b)}$.

⇒ méthode "basique" / "pivot" : analogie monde bootstrap

▶ $\theta \rightarrow \hat{\theta} ; \hat{\theta} \rightarrow \hat{\theta}^*$

Deux définitions considérées :

1. IC des percentiles : $[q_{\alpha/2}^* ; q_{1-\alpha/2}^*]$.
2. IC basique : $[2\hat{\theta} - q_{1-\alpha/2}^* ; 2\hat{\theta} - q_{\alpha/2}^*]$.

⇒ se basent uniquement sur q_{α}^* : le quantile d'ordre α des estimations bootstrap $\hat{\theta}^{*(b)}$.

⇒ méthode "basique" / "pivot" : analogie monde bootstrap

▶ $\theta \rightarrow \hat{\theta} ; \hat{\theta} \rightarrow \hat{\theta}^*$

De nombreuses autres définitions existent.

- ▶ normal, "studentisé", accéléré, corrigé du biais...

Applications : bootstrap et régression

Objectif : prédire / modéliser une variable $Y \in \mathbb{R}$ à partir de p variables explicatives $X^j \in \mathbb{R}$.

Modèle :

$$Y = \beta_0 + \sum_{j=1}^p \beta_j X^j + \epsilon \quad \text{avec } \epsilon \text{ un terme d'erreur.}$$

Introduction

Formalisation

Bootstrap pour l'inférence

Caractérisation d'un estimateur
Intervalles de confiance

Applications

Bootstrap & régression
Bootstrap & prédiction

Conclusion

Références

Objectif : prédire / modéliser une variable $Y \in \mathbb{R}$ à partir de p variables explicatives $X^j \in \mathbb{R}$.

Modèle :

$$Y = \beta_0 + \sum_{j=1}^p \beta_j X^j + \epsilon \quad \text{avec } \epsilon \text{ un terme d'erreur.}$$

\Rightarrow on estime les coefficients β_j par **moindre carrés**

- ▶ à partir d'un échantillon $(X_i, Y_i) \in \mathbb{R}^p \times \mathbb{R}$, $i = 1, \dots, n$

Introduction

Formalisation

Bootstrap pour l'inférence

Caractérisation d'un estimateur
Intervalle de confiance

Applications

Bootstrap & régression
Bootstrap & prédiction

Conclusion

Références

Objectif : prédire / modéliser une variable $Y \in \mathbb{R}$ à partir de p variables explicatives $X^j \in \mathbb{R}$.

Modèle :

$$Y = \beta_0 + \sum_{j=1}^p \beta_j X^j + \epsilon \quad \text{avec } \epsilon \text{ un terme d'erreur.}$$

\Rightarrow on estime les coefficients β_j par **moindre carrés**

- ▶ à partir d'un échantillon $(X_i, Y_i) \in \mathbb{R}^p \times \mathbb{R}$, $i = 1, \dots, n$

\Rightarrow **sous l'hypothèse que les résidus ϵ_i sont iid selon $\mathcal{N}(0, \sigma^2)$**
on connaît la distribution d'échantillonnage des $\hat{\beta}_j$.

- ▶ on peut donc en tirer des intervalles de confiance

Introduction

Formalisation

Bootstrap pour
l'inférenceCaractérisation
d'un estimateur
Intervalles de
confiance

Applications

**Bootstrap &
régression**
Bootstrap &
prédiction

Conclusion

Références

Bootstrap et régression = alternative non-paramétrique.

- ▶ relâcher les hypothèses du modèle.

Objectif : estimer la distribution d'échantillonnage des $\hat{\beta}_j$.

- ▶ in fine : calcul d'intervalles de confiance comme avant.

Deux stratégies principales :

1. bootstrap **par paires**
2. bootstrap **des résidus**

Bootstrap par paires

Principe : tirer avec remise dans $\{(X_i, Y_i)\}_{i=1, \dots, n}$.

Procédure bootstrap :

- ▶ On dispose d'un échantillon (Z_1, \dots, Z_n) , $Z_i = (X_i, Y_i)$
- ▶ On estime $\hat{\beta}_j$ sur l'échantillon original
- ▶ On applique le **bootstrap par paires** :
 - ▶ pour b de 1 à B
 - ▶ on génère un échantillon (Z_1^*, \dots, Z_n^*)
 - ▶ on estime les coefficients $\hat{\beta}_j^*$ à partir des (Z_1^*, \dots, Z_n^*)

Bootstrap par paires

Principe : tirer avec remise dans $\{(X_i, Y_i)\}_{i=1, \dots, n}$.

Procédure bootstrap :

- ▶ On dispose d'un échantillon (Z_1, \dots, Z_n) , $Z_i = (X_i, Y_i)$
- ▶ On estime $\hat{\beta}_j$ sur l'échantillon original
- ▶ On applique le **bootstrap par paires** :
 - ▶ pour b de 1 à B
 - ▶ on génère un échantillon (Z_1^*, \dots, Z_n^*)
 - ▶ on estime les coefficients $\hat{\beta}_j^*$ à partir des (Z_1^*, \dots, Z_n^*)

⇒ l'approche "standard".

⇒ hypothèse : (X_i, Y_i) iid selon une loi (jointe) P .

Bootstrap des résidus

Principe : travailler à partir des **résidus** du modèle initial.

Procédure bootstrap :

- ▶ On dispose d'un échantillon (Z_1, \dots, Z_n) , $Z_i = (X_i, Y_i)$
- ▶ On estime $\hat{\beta}_j$ sur l'échantillon original
- ▶ On considère les résidus $(\epsilon_1, \dots, \epsilon_n)$
- ▶ On applique le **bootstrap par résidus** :
 - ▶ pour b de 1 à B
 - ▶ on génère un échantillon $(\epsilon_1^*, \dots, \epsilon_n^*)$
 - ▶ on calcule $Y_i^* = \hat{\beta}_0 + \sum_{j=1}^p \hat{\beta}_j X_{ij} + \epsilon_i^*$
 - ▶ on estime les coefficients $\hat{\beta}_j^*$ à partir des (X_i, Y_i^*)

Bootstrap des résidus

Principe : travailler à partir des **résidus** du modèle initial.

Procédure bootstrap :

- ▶ On dispose d'un échantillon (Z_1, \dots, Z_n) , $Z_i = (X_i, Y_i)$
- ▶ On estime $\hat{\beta}_j$ sur l'échantillon original
- ▶ On considère les résidus $(\epsilon_1, \dots, \epsilon_n)$
- ▶ On applique le **bootstrap par résidus** :
 - ▶ pour b de 1 à B
 - ▶ on génère un échantillon $(\epsilon_1^*, \dots, \epsilon_n^*)$
 - ▶ on calcule $Y_i^* = \hat{\beta}_0 + \sum_{j=1}^p \hat{\beta}_j X_{ij} + \epsilon_i^*$
 - ▶ on estime les coefficients $\hat{\beta}_j^*$ à partir des (X_i, Y_i^*)

⇒ on tire avec remise les **résidus**.

- ▶ tous les X_i sont utilisés à chaque fois
- ▶ hypothèse : $Y_i|X_i$ iid

⇒ semble être la stratégie la plus classique

Applications : bootstrap et modèles de prédiction

Stratégie bootstrap & "bagging"

Principe bootstrap pour la construction de prédicteurs :

Introduction

Formalisation

Bootstrap pour
l'inférence

Caractérisation
d'un estimateur
Intervalle de
confiance

Applications

Bootstrap &
régression
**Bootstrap &
prédiction**

Conclusion

Références

Stratégie bootstrap & "bagging"

Principe bootstrap pour la construction de prédicteurs :

1. **Apprentissage** : construire B prédicteurs à partir d'échantillons obtenus en tirant avec remise dans l'échantillon original.

Stratégie bootstrap & "bagging"

Principe bootstrap pour la construction de prédicteurs :

1. **Apprentissage** : construire B prédicteurs à partir d'échantillons obtenus en tirant avec remise dans l'échantillon original.
2. **Prédiction** : agréger les prédictions des B modèles
 - ▶ **régression** : prédire la moyenne des valeurs obtenues.
 - ▶ **classification** : prédire la classe prédite le plus souvent

Introduction

Formalisation

Bootstrap pour l'inférence

Caractérisation d'un estimateur
Intervalles de confiance

Applications

Bootstrap & régression
Bootstrap & prédiction

Conclusion

Références

Stratégie bootstrap & "bagging"

Principe bootstrap pour la construction de prédicteurs :

1. **Apprentissage** : construire B prédicteurs à partir d'échantillons obtenus en tirant avec remise dans l'échantillon original.
2. **Prédiction** : agréger les prédictions des B modèles
 - ▶ **régression** : prédire la moyenne des valeurs obtenues.
 - ▶ **classification** : prédire la classe prédite le plus souvent

On parle de stratégie **bagging**, pour **bootstrap-aggregating**.

Stratégie générique, souvent basée sur des arbres de décision

En pratique elle permet de **limiter le sur-apprentissage**.

Stratégie bootstrap & "bagging"

Principe bootstrap pour la construction de prédicteurs :

1. **Apprentissage** : construire B prédicteurs à partir d'échantillons obtenus en tirant avec remise dans l'échantillon original.
2. **Prédiction** : agréger les prédictions des B modèles
 - ▶ **régression** : prédire la moyenne des valeurs obtenues.
 - ▶ **classification** : prédire la classe prédite le plus souvent

On parle de stratégie **bagging**, pour **bootstrap-aggregating**.

Stratégie générique, souvent basée sur des arbres de décision

En pratique elle permet de **limiter le sur-apprentissage**.

⇒ à suivre dans cours "**Apprentissage Statistique II**".

Introduction

Formalisation

Bootstrap pour
l'inférence

Caractérisation
d'un estimateur
Intervalles de
confiance

Applications

Bootstrap &
régression
Bootstrap &
prédiction

Conclusion

Références

Conclusion

- ▶ Bootstrap : un principe très simple à mettre en oeuvre.

- ▶ Bootstrap : un principe très simple à mettre en oeuvre.
- ▶ Il permet de répondre à des questions d'inférence statistique sans aucune information sur la loi de la variable aléatoire sous-jacente.

- ▶ Bootstrap : un principe très simple à mettre en oeuvre.
- ▶ Il permet de répondre à des questions d'inférence statistique sans aucune information sur la loi de la variable aléatoire sous-jacente.
- ▶ Dans ce cas là, travailler par ré-échantillonnage de l'échantillon disponible est parfois la meilleure stratégie, surtout si la loi sous-jacente n'est pas une loi usuelle.

► Intérêts principaux :

1. relâcher les hypothèses sur la loi de la variable aléatoire étudiée qu'on doit faire avec les approches paramétriques
2. principe générique applicable à n'importe quelle statistique (dont on ne connaît pas la distribution)

- ▶ Intérêts principaux :
 1. relâcher les hypothèses sur la loi de la variable aléatoire étudiée qu'on doit faire avec les approches paramétriques
 2. principe générique applicable à n'importe quelle statistique (dont on ne connaît pas la distribution)
- ▶ Bien garder en tête qu'il y a 2 niveaux d'approximation
 1. remplacer la "vraie" distribution par l'empirique
 2. remplacer la "vraie" distribution d'échantillonnage (selon la loi empirique) par celle obtenue par tirages

- ▶ Intérêts principaux :
 1. relâcher les hypothèses sur la loi de la variable aléatoire étudiée qu'on doit faire avec les approches paramétriques
 2. principe générique applicable à n'importe quelle statistique (dont on ne connaît pas la distribution)
- ▶ Bien garder en tête qu'il y a 2 niveaux d'approximation
 1. remplacer la "vraie" distribution par l'empirique
 2. remplacer la "vraie" distribution d'échantillonnage (selon la loi empirique) par celle obtenue par tirages
- ▶ Par conséquent : méthode valide quand n est grand
 - ▶ résultats théoriques pour démontrer la validité des procédures décrites (caractérisation et IC)
 - ▶ le bootstrap n'est **pas** dédié aux petits échantillons

- ▶ Intérêts principaux :
 1. relâcher les hypothèses sur la loi de la variable aléatoire étudiée qu'on doit faire avec les approches paramétriques
 2. principe générique applicable à n'importe quelle statistique (dont on ne connaît pas la distribution)
- ▶ Bien garder en tête qu'il y a 2 niveaux d'approximation
 1. remplacer la "vraie" distribution par l'empirique
 2. remplacer la "vraie" distribution d'échantillonnage (selon la loi empirique) par celle obtenue par tirages
- ▶ Par conséquent : méthode valide quand n est grand
 - ▶ résultats théoriques pour démontrer la validité des procédures décrites (caractérisation et IC)
 - ▶ le bootstrap n'est **pas** dédié aux petits échantillons
- ▶ Et si n est petit ? Pas forcément pire qu'une approche paramétrique...

- ▶ Le principe du bootstrap a été décliné avec succès pour **construire des modèles de prédiction**, dans une stratégie dite de **bagging**.

- ▶ Le principe du bootstrap a été décliné avec succès pour **construire des modèles de prédiction**, dans une stratégie dite de **bagging**.
- ▶ Un exemple important est celui des **forêts aléatoires**, qui sont des **classifieurs très performants** et relativement simples à mettre en oeuvre.

- ▶ Le principe du bootstrap a été décliné avec succès pour **construire des modèles de prédiction**, dans une stratégie dite de **bagging**.
- ▶ Un exemple important est celui des **forêts aléatoires**, qui sont des **classifieurs très performants** et relativement simples à mettre en oeuvre.
- ▶ On peut également utiliser ce principe pour **évaluer les performances d'un modèle de prédiction**, comme une alternative à la **validation croisée**.
 - ▶ mais c'est moins classique.

⇒ à suivre dans le cours "**Apprentissage Statistique II**".

Le pilier du bootstrap :

```
> ind.bs = sample(n, replace = TRUE)
```

Les packages `bootstrap` et `boot` implémentent les méthodes vues en cours.

Le package `boot` est le plus recommandé.

- ▶ extrait tiré de la documentation du package `bootstrap` : *New projects should preferentially use the recommended package "boot"*

Package `boot` : deux fonctions principales

1. fonction `boot()`

- ▶ en entrée : données, statistique considérée (une fonction) et B .
- ▶ en sortie : un objet contenant (en 1er lieu) les estimations bootstrap.
- ▶ la fonction `print()` affiche le biais et l'erreur type.

2. fonction `boot.ci()`

- ▶ en entrée : l'objet retourné par la fonction `boot()`.
- ▶ en sortie : les intervalles de confiance par différentes stratégies (e.g., `basic`, `perc`, `norm`).

⇒ à voir en TP.

B. Efron and R. Tibshirani. *An introduction to the bootstrap*.
Chapman & Hall, 1993.