

# Kapitel 5

## Einführung in Bootstrap

*Literatur zum Thema:*

- Efron B., Tibshirani R.J.: An Introduction to the Bootstrap (1993)
- Hall P.: The Bootstrap and Edgeworth Expansion (1992)
- Davison A.C.: Recent Developments in Bootstrap Methodology, Statistical Science (2003), Vol. 18, No. 2, pp. 141-157

### 5.1 Einführung

- *Bootstrap* (engl.): Stiefelriemen, Stiefelschlaufe
- „Sich selbst am Schopf aus dem Sumpf ziehen“ → Lügenbaron Münchhausen (mit Pferd)
- Computergestützte Methode
- Beruht auf wiederholtem Ziehen (*Resampling*) aus den beobachteten Daten.
- *Ziel*: Schätzung von Varianz, Bias oder Verteilung einer Statistik  $T = T(X_1, \dots, X_n)$ , Konfidenzintervalle, Tests.
- Wann? In Situationen, in denen
  - (a) asymptotische Aussagen fragwürdig sind (kleine Stichprobenumfänge),
  - (b) analytische Berechnungen sehr kompliziert oder unmöglich sind, zum Beispiel wenn keine parametrischen Verteilungsannahmen gemacht werden sollen. → Bootstrap für nichtparametrische Schätzungen.
- Funktioniert „Bootstrap“ immer? Nein, nicht immer (Bootstrap kann *inkonsistent* sein), aber oft.



### 5.1.1 Grundidee

Einstichproben-Problem:  $X = (X_1, \dots, X_n)$ ,  $X_i \stackrel{i.i.d.}{\sim} F$ ,  $F$  unbekannt

Interessierende Statistik:  $T(X)$

Beobachtete Daten:  $x = (x_1, x_2, \dots, x_n) \rightarrow T(x)$

*Bootstrap-Stichprobe:* Ziehe  $n$  mal mit Zurücklegen zufällig aus  $(x_1, \dots, x_n)$ . Wir erhalten

$$x^* = (x_1^*, x_2^*, \dots, x_n^*) \rightarrow T(x^*).$$


*Beispiel:*  $x = (1, 2, 5)$ ,  $n = 3$ .  $x^* = (1, 1, 5)$  ist eine mögliche Bootstrap-Stichprobe.

*Also:*

- (1) Werte aus der ursprünglichen Stichprobe  $x$  können in der Bootstrap-Stichprobe
  - (i) einmal vorkommen,
  - (ii) mehrfach vorkommen,
  - (iii) gar nicht vorkommen.

(2) Die Bootstrap-Stichprobe hat ebenfalls Stichprobenumfang  $n$ .

Skizze:



$B$ : Anzahl von Bootstrap-Stichproben

Mit den berechneten Statistiken  $T(x^{*1}), \dots, T(x^{*B})$  lassen sich Aussagen über die Verteilung von  $T$  gewinnen, zum Beispiel

$$\text{Var}_F(T) \approx \widehat{\text{Var}}_{\text{Boot}}(T) = \left\{ \frac{1}{B-1} \sum_{b=1}^B [T(x^{*b}) - \bar{T}_{\text{Boot}}]^2 \right\}$$

mit

$$\bar{T}_{\text{Boot}} = \frac{1}{B} \sum_{b=1}^B T(x^{*b}).$$

### 5.1.2 Empirische Verteilungsfunktion und das Plug-In-Prinzip

$X = (X_1, \dots, X_n)$ ,  $X_i \stackrel{i.i.d.}{\sim} F$ ,  $F$  unbekannt

$x = (x_1, x_2, \dots, x_n)$  Daten

Empirische Verteilungsfunktion:

$$\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n I(x_i \leq x),$$

wobei  $I$  die Indikatorfunktion ist.

Plug-In-Prinzip:  $F$  durch  $\hat{F}_n$  ersetzen.

### Beispiel 5.1.

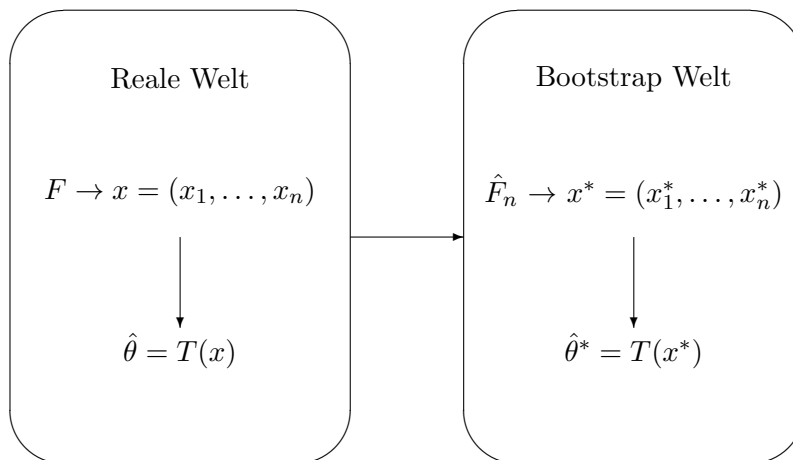
$$\begin{aligned}T(F) &= \mu = \int x dF(x) \\T(\hat{F}_n) &= \int x d\hat{F}_n(x) \\&= \sum_{i=1}^n x_i \hat{P}_n(X = x_i) \quad (\text{o.w.E. seien alle } x_i \text{ verschieden}) \\&= \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}\end{aligned}$$

Plug-In-Prinzip hat Sinn, wenn *keine weiteren Informationen über  $F$*  vorhanden sind außer der Stichprobe.

→ „nichtparametrisches Setup“

### 5.1.3 Reale Welt und Bootstrap-Welt

Wiederum Einstichproben-Fall:



- Die unbekannte Verteilung  $F$  liefert  $x$  als Zufallsstichprobe.
  - Die empirische Verteilung  $\hat{F}_n$  liefert  $x^*$  als zufällige Bootstrap-Stichprobe.
  - Die interessierende Statistik  $\hat{\theta} = T(x)$  ist Funktion der Zufallsstichprobe.
  - Die Bootstrap-Replikation  $\hat{\theta}^* = T(x^*)$  ist Funktion der Bootstrap-Stichprobe.
- ⇒ Im Allgemeinen kann  $F$  bzw.  $\hat{F}_n$  in obiger Abbildung durch ein *geschätztes* Wahrscheinlichkeitsmodell  $P$  bzw.  $\hat{P}_n$  ersetzt werden.

### 5.1.4 Die ideale Bootstrap-Verteilung

Daten  $x = (x_1, x_2, \dots, x_n)$ .

*Frage:* Wie viele verschiedene Bootstrap-Stichproben gibt es?

**Beispiel 5.2.** Sei  $x = (1, 2, 5)$ . Die Anordnung spielt hier keine Rolle. Wegen  $n = 3$  gibt es 10 verschiedene Bootstrap-Stichproben (wenn alle  $x_i$  verschieden sind):

$$(1, 1, 1), (2, 2, 2), (5, 5, 5), (1, 1, 2), (1, 1, 5), (2, 2, 5), (1, 2, 2), (1, 5, 5), (2, 5, 5), (1, 2, 5).$$

Die ideale Bootstrap-Schätzung ist die, welche sich durch Berücksichtigung aller möglichen Bootstrap-Stichproben ergibt. Die ideale Bootstrap-Schätzung zum Beispiel für die Varianz von  $\hat{\theta} = \text{median}(X)$  in Beispiel 5.2 wäre dabei die Varianz über die 10 Bootstrap-Stichproben. Dabei ist allerdings zu berücksichtigen, dass die Stichproben mit unterschiedlicher Wahrscheinlichkeit gezogen werden.

**Beispiel 5.3** (Fortsetzung von Beispiel 5.2). Mit Hilfe der Multinomialverteilung erhält man

$$\begin{aligned} P(x^* = (1, 1, 1)) &= \frac{3!}{3!0!0!} \cdot \left(\frac{1}{3}\right)^3 \left(\frac{1}{3}\right)^0 \left(\frac{1}{3}\right)^0 = \left(\frac{1}{3}\right)^3 = \left(\frac{1}{27}\right), \\ P(x^* = (2, 5, 5)) &= \frac{3!}{0!1!2!} \cdot \left(\frac{1}{3}\right)^0 \left(\frac{1}{3}\right)^1 \left(\frac{1}{3}\right)^2 = 3 \cdot \left(\frac{1}{3}\right)^3 = \left(\frac{1}{9}\right), \\ P(x^* = (1, 2, 5)) &= \frac{3!}{1!1!1!} \cdot \left(\frac{1}{3}\right) \left(\frac{1}{3}\right) \left(\frac{1}{3}\right) = 6 \cdot \left(\frac{1}{3}\right)^3 = \left(\frac{2}{9}\right), \end{aligned}$$

denn zum Beispiel  $(2, 5, 5) \hat{=} (5, 2, 5) \hat{=} (5, 5, 2) \hat{=} (1, 2, 5) \hat{=} \dots \hat{=} (5, 2, 1)$ .

Betrachte  $\hat{\theta} = \text{median}(X)$ . Dann ist  $\hat{\theta}(x) = 2$  die Schätzung aus der Stichprobe und

$$\begin{aligned} \text{Var}_{\hat{F}_n}(\hat{\theta}^*) &= \left(\frac{1}{3}\right)^3 \{ (1-c)^2 + (2-c)^2 + (5-c)^2 \\ &\quad + 3 \cdot [(1-c)^2 + (1-c)^2 + (2-c)^2 + (2-c)^2 + (5-c)^2 + (5-c)^2] \\ &\quad + 6 \cdot (2-c)^2 \} \\ &= 2.32, \end{aligned}$$

wobei

$$\begin{aligned} c = \bar{\theta}^* &= \left(\frac{1}{3}\right)^3 [1 + 2 + 5 + 3 \cdot (1 + 1 + 2 + 2 + 5 + 5) + 6 \cdot 2] \\ &= \left(\frac{1}{3}\right)^3 [8 + 3 \cdot 16 + 12] = \left(\frac{1}{3}\right)^3 \cdot 68 = \frac{68}{27} \approx 2.5 \end{aligned}$$

der Mittelwert aller geschätzten Mediane ist.

Allgemein gibt es, sofern alle  $n$  Datenpunkte  $x_1, \dots, x_n$  *verschieden* sind,  $\binom{2n-1}{n}$  mögliche Bootstrap-Stichproben.

$$\begin{aligned} n = 3 : & \quad \binom{5}{3} = 10 \\ n = 15 : & \quad \binom{29}{15} = 77\,558\,760 \\ n = 20 : & \quad \binom{39}{20} = 68\,923\,264\,410 \end{aligned}$$

Das heißt, wenn  $n$  nicht sehr klein ist, dann ist es praktisch nicht möglich, die ideale Bootstrap-Verteilung zu verwenden. Stattdessen begnügt man sich mit einer Anzahl  $B \ll \binom{2n-1}{n}$  von Bootstrap-Stichproben.

## 5.2 Bootstrap-Schätzung eines Standardfehlers

Einstichproben-Fall:  $X = (X_1, \dots, X_n)$ ,  $X_i \stackrel{\text{i.i.d.}}{\sim} F$ ,  $F$  unbekannt

Daten:  $x = (x_1, \dots, x_n)$

Ziel dieses Abschnitts ist die Schätzung des Standardfehlers eines Schätzers  $\hat{\theta} = \hat{\theta}(X)$  für  $\theta = T(F)$ . Hierbei *kann*  $\hat{\theta}(X)$  die Plug-In-Schätzung  $T(\hat{F}_n)$  sein, muss aber nicht.

*Frage:* Wie gut ist die Schätzung  $\hat{\theta}$ ?

### 5.2.1 Bootstrap-Algorithmus zur Schätzung des Standardfehlers

---

**Algorithmus 12: Bootstrap-Algorithmus zur Schätzung des Standardfehlers**

---

1. Erzeuge  $B$  Bootstrap-Stichproben  $x^{*1}, \dots, x^{*B}$ .
2. Berechne  $\hat{\theta}^*(b)$ ,  $b = 1, \dots, B$ .
3. Schätze den Standardfehler  $\text{se}_F(\hat{\theta}) = \sqrt{\text{Var}_F(\hat{\theta})}$  durch

$$\widehat{\text{se}}_B = \left\{ \frac{1}{B-1} \sum_{b=1}^B \left[ \hat{\theta}^*(b) - \hat{\theta}^*(\cdot) \right]^2 \right\}^{\frac{1}{2}} \quad \text{mit} \quad \hat{\theta}^*(\cdot) = \frac{1}{B} \sum_{b=1}^B \hat{\theta}^*(b).$$

---

Die Bootstrap-Schätzung für den Standardfehler  $\text{se}_F(\hat{\theta})$  einer Schätzung  $\hat{\theta}$  (Daten aus  $F$ ) ist also der Standardfehler für zufällige Stichproben vom *Umfang*  $n$  gezogen aus  $\hat{F}_n$  mit Zurücklegen.

Es gilt:

$$\lim_{B \rightarrow \infty} \widehat{\text{se}}_B = \text{se}_{\hat{F}_n}(\hat{\theta}^*).$$

Die ideale Bootstrap-Schätzung  $se_{\hat{F}_n}(\hat{\theta}^*)$  und die Approximation  $\hat{se}_B$  werden oft als *nichtparametrische Bootstrap-Schätzung* bezeichnet, da sie nur auf  $\hat{F}_n$  beruhen und  $\hat{F}_n$  die nichtparametrische Schätzung für  $F$  ist.

→ Abschnitt 5.2.3: Parametrischer Bootstrap ( $F$  wird nicht mehr durch  $\hat{F}_n$  geschätzt).

**Beispiel 5.4.** Zwei (quasi-) stetige Merkmale  $Y$  und  $Z$  werden an  $n$  Individuen erhoben, d.h.

$$X = ((Y_1, Z_1), (Y_1, Z_1), \dots, (Y_n, Z_n)), \quad (Y_i, Z_i) \stackrel{i.i.d.}{\sim} F_{Y,Z}.$$

Gesucht: Schätzung für den Standardfehler des Korrelationskoeffizienten von  $Y$  und  $Z$ .

## 5.2.2 Anzahl der Replikationen

Die Anzahl der Replikationen  $B$  wird durch folgende Überlegungen bestimmt:

- (i) Praktische Überlegungen: Wenn  $\hat{\theta}(x^*)$  eine komplizierte Funktion von  $x^*$  ist, dann wird  $B$  kleiner sein müssen als wenn  $\hat{\theta}(x^*)$  eine einfache Funktion von  $x^*$  ist.
- (ii) Genauigkeitsüberlegungen: Es gilt

$$\text{Var}(\hat{se}_B) > \text{Var}\left(\underbrace{se_{\hat{F}_n}(\hat{\theta}^*)}_{\text{ideale Bootstrap-Schätzung}}\right).$$

Die Frage ist, um wieviel die Varianz von  $\hat{se}_B$  größer ist.

Aus theoretischen Überlegungen ergibt sich, dass  $B = 200$  im Einstichproben-Problem in der Regel ausreichend ist zur Schätzung eines Standardfehlers. Für Konfidenzintervalle werden deutlich mehr Replikationen benötigt ( $B \approx 2000$ ).

## 5.2.3 Parametrischer Bootstrap

**Definition 5.1.** Die parametrische Bootstrap-Schätzung des Standardfehlers ist definiert durch

$$se_{\hat{F}_{n,par}}(\hat{\theta}^*),$$

wobei  $\hat{F}_{n,par}$  eine Schätzung von  $F$ , abgeleitet aus einem parametrischen Modell, ist.

**Beispiel 5.5.** Sei  $X = ((Y_1, Z_1)', \dots, (Y_n, Z_n)')$  mit

$$\begin{pmatrix} Y_i \\ Z_i \end{pmatrix} \stackrel{i.i.d.}{\sim} F_{Y,Z}.$$

Annahme:  $F_{Y,Z}$  sei eine bivariate Normalverteilung und

$$\hat{\mu} = \begin{pmatrix} \bar{y} \\ \bar{z} \end{pmatrix},$$

$$\hat{\Sigma} = \frac{1}{n} \begin{pmatrix} \sum_{i=1}^n (y_i - \bar{y})^2 & \sum_{i=1}^n (y_i - \bar{y})(z_i - \bar{z}) \\ \sum_{i=1}^n (y_i - \bar{y})(z_i - \bar{z}) & \sum_{i=1}^n (z_i - \bar{z})^2 \end{pmatrix}.$$

Das heißt, wir verwenden jetzt  $\hat{F}_{n,par} = N_2(\hat{\mu}, \hat{\Sigma})$  als Schätzung für  $F$ , und statt Bootstrap-Stichproben aus den Daten zu ziehen, ziehen wir Bootstrap-Stichproben aus dieser bivariaten Normalverteilung:

$$\left. \begin{aligned} x^{*1} &= ((Y_1^{*1}, Z_1^{*1})', \dots, (Y_n^{*1}, Z_n^{*1})') \\ &\vdots \\ x^{*B} &= ((Y_1^{*B}, Z_1^{*B})', \dots, (Y_n^{*B}, Z_n^{*B})') \end{aligned} \right\} \sim N_2(\hat{\mu}, \hat{\Sigma}).$$

Danach geht es weiter wie gewohnt!

**Beispiel 5.6** (Standardfehler für die Schätzung des Korrelationskoeffizienten  $\theta$ ).

(i) Vergleich mit der Formel für die bivariate Normalverteilung:

$$\widehat{\text{se}}_{N_2(\mu, \Sigma)}(\hat{\theta}) = \frac{1 - \hat{\theta}^2}{\sqrt{n - 3}}.$$

(ii) Vergleich nach Fisher-Transformation:

$$\hat{\xi} = \frac{1}{2} \log \left( \frac{1 + \hat{\theta}}{1 - \hat{\theta}} \right) \underset{\text{approx.}}{\sim} N \left[ \frac{1}{2} \log \left( \frac{1 + \theta}{1 - \theta} \right), \left( \frac{1}{\sqrt{n - 3}} \right)^2 \right].$$

Um dieses Resultat auszunutzen, könnte Inferenz für  $\hat{\xi}$  betrieben und anschließend durch Rücktransformation auf den wahren Korrelationskoeffizienten  $\theta$  übertragen werden.

### 5.2.4 Ein Beispiel, bei dem der nichtparametrische Bootstrap nicht klappt

Betrachte  $X = (X_1, \dots, X_n)$  mit  $X_i \stackrel{\text{i.i.d.}}{\sim} \text{Unif}(0, \theta)$ . Bekannt sei das Maximum  $\hat{\theta}_{ML} = X_{(n)}$ . Die Wahrscheinlichkeit, dass  $X_{(n)}$  nicht in der Bootstrap-Stichprobe auftritt, ist  $(1 - \frac{1}{n})^n$ . Die Wahrscheinlichkeit, dass  $X_{(n)}$  in der Bootstrap-Stichprobe vorkommt, ist also

$$1 - \left(1 - \frac{1}{n}\right)^n \rightarrow 1 - e^{-1} \approx 0.632 \quad \text{für } n \rightarrow \infty.$$

Das heißt  $P(\hat{\theta}^* = \hat{\theta}_{ML}) \approx 0.632$  für  $n \rightarrow \infty$ , die Verteilung von  $\hat{\theta}^*$  legt also eine Wahrscheinlichkeitsmasse von 0.632 auf den ML-Schätzer. Dieser wird also reproduziert und es gibt damit keinen Informationsgewinn aus diesen Stichproben!

*Problem:*  $\hat{F}_n$  ist keine gute Schätzung für  $F$  in den extremen Bereichen von  $F$ .

Beim parametrischen Bootstrap gilt dagegen

$$X^* = (X_1^*, \dots, X_n^*) \text{ mit } X_i^* \sim \text{Unif}(0, \hat{\theta}_{ML})$$

und deshalb

$$\mathbb{P}(\hat{\theta}^* = \hat{\theta}_{ML}) = 0.$$

*Also:* Nichtparametrischer Bootstrap kann schiefgehen!



### 5.2.5 Zweistichproben-Problem für unabhängige Stichproben

Seien

$$\left. \begin{array}{l} Y_1, \dots, Y_n \stackrel{\text{i.i.d.}}{\sim} F \\ Z_1, \dots, Z_m \stackrel{\text{i.i.d.}}{\sim} G \end{array} \right\} \text{unabhängig, zum Beispiel } \begin{cases} F : \text{Behandlung} \\ G : \text{Kontrolle} \end{cases}$$

und  $X = (Y_1, \dots, Y_n, Z_1, \dots, Z_m)$  bzw.  $x = (y_1, \dots, y_n, z_1, \dots, z_m)$ .

*Ziel:* Schätzung des Standardfehlers der Schätzung für die Differenz  $\theta = \underbrace{\mu_Y}_{\mathbb{E}(Y_i)} - \underbrace{\mu_Z}_{\mathbb{E}(Z_i)}$ .

Betrachte

$$\hat{\theta} = \bar{y} - \bar{z}.$$

Vorgehen bei der  $b$ -ten Bootstrap-Stichprobe:

$$\begin{aligned} y^{*b} &= (y_1^{*b}, \dots, y_n^{*b}) \text{ zufällig mit Zurücklegen aus } \hat{F}_n \\ z^{*b} &= (z_1^{*b}, \dots, z_m^{*b}) \text{ zufällig mit Zurücklegen aus } \hat{G}_m \end{aligned}$$

*Schätzung:*

$$\underbrace{\widehat{\text{se}}_{F,G}(\hat{\theta})}_{\text{Real World}} = \underbrace{\text{se}_{\hat{F}_n, \hat{G}_m}(\hat{\theta}^*)}_{\substack{\text{ideale} \\ \text{Schätzung in} \\ \text{der Bootstrap-} \\ \text{World}}} \approx \underbrace{\widehat{\text{se}}_B}_{\substack{\text{Approx.} \\ \text{der idealen} \\ \text{Bootstrap-} \\ \text{Schätzung}}} = \left\{ \frac{1}{B-1} \sum_{b=1}^B [\hat{\theta}^*(b) - \hat{\theta}^*(\cdot)]^2 \right\}^{\frac{1}{2}}$$

mit

$$\hat{\theta}^*(b) = \bar{y}^{*b} - \bar{z}^{*b} = \frac{1}{n} \sum_{i=1}^n y_i^{*b} - \frac{1}{m} \sum_{i=1}^m z_i^{*b}$$

und

$$\hat{\theta}^*(\cdot) = \frac{1}{B} \sum_{b=1}^B (\bar{y}^{*b} - \bar{z}^{*b}) = \frac{1}{B} \sum_{b=1}^B \hat{\theta}^*(b).$$

### 5.2.6 Bootstrap für eine Zeitreihe

Betrachte die Zeitreihe  $y_1, y_2, \dots, y_T$  und die zentrierte Zeitreihe  $z_1, z_2, \dots, z_T$  mit  $z_t = y_t - \bar{y}$  für  $t = 1, \dots, T$ .

*Annahmen:* Es handelt sich um einen AR(1)-Prozess

$$z_t = \beta z_{t-1} + \varepsilon_t \quad (t = 2, \dots, T)$$

mit Anfangsbedingung  $z_1$ ,  $|\beta| < 1$  und  $\varepsilon_t \stackrel{\text{i.i.d.}}{\sim} F$  für  $t = 2, \dots, T$ ,  $F$  unbekannt und  $\mathbb{E}(\varepsilon_t) = 0$ . Die KQ-Schätzung für  $\beta$  lautet:

$$\sum_{t=2}^T (z_t - \beta z_{t-1})^2 \rightarrow \min_{\beta} \rightarrow \hat{\beta}.$$

(Da hier keine Verteilungsannahme getroffen wurde, ist ML-Schätzung nicht möglich.)

*Gesucht:* Schätzung für  $\text{se}_{F,\beta}(\hat{\beta})$ .

*Idee:* Berechne Residuen

$$\left. \begin{array}{l} \hat{\varepsilon}_2 = z_2 - \hat{\beta}z_1, \\ \vdots \\ \hat{\varepsilon}_T = z_T - \hat{\beta}z_{T-1}. \end{array} \right\} T - 1 \text{ Residuen}$$

Bezeichne mit  $\hat{F}_{T-1}$  die empirische Verteilungsfunktion der  $\hat{\varepsilon}_2, \dots, \hat{\varepsilon}_T$ . Dann erhält man die  $b$ -te *Bootstrap-Stichprobe* wie folgt:

- (i) Ziehe  $\varepsilon_2^{*b}, \dots, \varepsilon_T^{*b}$  zufällig mit Zurücklegen aus  $\hat{F}_{T-1}$ .
- (ii) Berechne rekursiv

$$\begin{aligned} z_1 &= y_1 - \bar{y} \\ z_2^{*b} &= \hat{\beta}z_1 + \varepsilon_2^{*b} \\ z_3^{*b} &= \hat{\beta}z_2^{*b} + \varepsilon_3^{*b} \\ &\vdots \\ z_T^{*b} &= \hat{\beta}z_{T-1}^{*b} + \varepsilon_T^{*b}. \end{aligned}$$

- (iii) Ermittle  $\hat{\beta}^{*b}$  mittels KQ aus  $z_2^{*b}, \dots, z_T^{*b}$ .

*Damit:*

$$\widehat{\text{se}}_{F,\beta}(\hat{\beta}) = \text{se}_{\hat{F}_{T-1},\hat{\beta}}(\hat{\beta}^*) \approx \widehat{\text{se}}_B(\hat{\beta}^*) = \left\{ \frac{1}{B-1} \sum_{b=1}^B [\hat{\beta}^{*b} - \hat{\beta}^*(\cdot)]^2 \right\}^{\frac{1}{2}}$$

mit

$$\hat{\beta}^*(\cdot) = \frac{1}{B} \sum_{b=1}^B \hat{\beta}^{*b}.$$

*Andere Idee:* „Moving Block Bootstrap“ (vgl. Efron und Tibshirani, 1993).

## 5.3 Bootstrap-Konfidenzintervalle

### 5.3.1 Einleitung

Übliches 90%-Konfidenzintervall:

$$\hat{\theta} \pm 1.645 \cdot \widehat{\text{se}}.$$

Übliches 95%-Konfidenzintervall:

$$\hat{\theta} \pm 1.96 \cdot \widehat{\text{se}}.$$

Dabei kann  $\hat{se}$  auch Bootstrap-Schätzung sein. Die Begründung dafür ist meist:

$$Z = \frac{\hat{\theta} - \theta}{\hat{se}} \underset{\text{approx.}}{\sim} N(0, 1) \quad (\text{asymptotische Aussage}) .$$

Die asymptotische Verteilung ist (approximativ) unabhängig von  $\theta$ ;  $Z$  wird approximatives Pivot genannt.

Wenn  $n$  klein ist, können die Quantile der Normalverteilung durch die Quantile der  $t$ -Verteilung ersetzt werden:

$$\hat{\theta} \pm t_{n-1}^{(1-\alpha/2)} \cdot \hat{se} .$$

*Idee:* Annahme der Normalverteilung vermeiden, Verteilung von  $Z$  aus den Daten schätzen. Dies wird in den folgenden Abschnitten beschrieben.

### 5.3.2 Bootstrap- $t$ -Intervall

Betrachte

$$Z = \frac{\hat{\theta} - \theta}{\hat{se}} , \tag{5.1}$$

wobei  $\hat{se}$  zunächst irgendeine „vernünftige“ Schätzung des Standardfehlers von  $\hat{\theta}$  darstellt.

*Idee:* Schätze Verteilung von  $Z$  wie folgt:

1. Generiere  $B$  Bootstrap-Stichproben  $x^{*1}, \dots, x^{*B}$ .
2. Berechne

$$Z^*(b) = \frac{\hat{\theta}^*(b) - \hat{\theta}}{\hat{se}^*(b)} ,$$

wobei  $\hat{se}^*(b)$  eine Schätzung des Standardfehlers von  $\hat{\theta}^*(b)$  ist. Ordne die  $Z^*(b)$  aufsteigend der Größe nach.

3. Schätze die Quantile  $\hat{t}^{(\alpha)}$  und  $\hat{t}^{(1-\alpha)}$  (für ein  $(1 - 2\alpha)$ -Konfidenzintervall) als

$$\frac{\#\{Z^*(b) \leq \hat{t}^{(\alpha)}\}}{B} = \alpha .$$

Dabei bezeichnet  $\#A$  die Kardinalität einer Menge  $A$ .

Beispiel: Für  $B = 1000$  ist  $\hat{t}^{(0.05)}$  der 50. Wert der geordneten  $Z^*(b)$ -Werte,  $\hat{t}^{(0.95)}$  ist der 950. Wert der geordneten  $Z^*(b)$ -Werte.


4. Das Bootstrap- $t$ -Intervall zum Vertrauensgrad  $1 - 2\alpha$  lautet dann

$$\left[ \hat{\theta} - \hat{t}^{(1-\alpha)} \cdot \hat{se}, \hat{\theta} - \hat{t}^{(\alpha)} \cdot \hat{se} \right]$$

mit  $\hat{se}$  aus Formel (5.1).

Analogie zur  $t$ -Verteilung:

$$\left[ \hat{\theta} - t^{1-\alpha} \cdot \hat{se}, \hat{\theta} + t^{1-\alpha} \cdot \hat{se} \right] \quad (t^{1-\alpha} = -t^\alpha) .$$



Beachte: Wenn  $B\alpha$  nicht ganzzahlig ist und  $\alpha \leq \frac{1}{2}$ , dann wähle  $k = \lfloor (B+1)\alpha \rfloor$ , das ist die größte ganze Zahl  $\leq (B+1)\alpha$ . Die empirischen Quantile sind dann der  $k$ -te Wert der geordneten  $Z^*(b)$ -Werte und der  $(B+1-k)$ -te Wert.

*Probleme:*

1. Das Bootstrap- $t$ -Intervall kann stark durch Ausreißer beeinflusst werden.
2. Betrachte nochmals

$$Z^*(b) = \frac{\hat{\theta}^*(b) - \hat{\theta}}{\hat{se}^*(b)}.$$

Wie kann man  $\hat{se}^*(b)$  schätzen?

- (i) Wenn  $\hat{\theta}$  der Mittelwert ist:

$$\hat{se}^*(b) = \frac{1}{n} \left\{ \sum_{i=1}^n (x_i^{*b} - \bar{x}^{*b})^2 \right\}^{\frac{1}{2}} \quad (\text{Plug-In-Schätzung}).$$

- (ii) Wenn  $\hat{\theta}$  komplizierter bzw. keine Standardformel verfügbar ist:

→ *Nested Bootstrap*: Es ist eine Bootstrap-Schätzung des Standardfehlers für *jede* Bootstrap-Stichprobe notwendig, zum Beispiel sind für  $B = 1000$  und  $B^* = 50$

$$BB^* = 1000 \cdot 50 = 50\,000$$

Stichproben notwendig. Wir sampeln also auf zwei verschachtelten Ebenen:

Real World → Bootstrap-World → Nested Bootstrap-World.

*Vorteil*: Dieser Vorgang ist parallelisierbar (im Gegensatz zu MCMC, wo die Kette nicht parallelisierbar ist).

3. Das Bootstrap- $t$ -Intervall wird von der Skala des Parameters beeinflusst, es ist nicht invariant gegenüber Transformationen. Bei kleinen Stichproben in nichtparametrischem Setup kann irreguläres Verhalten auftreten; hier kann jedoch eine Transformation der Parameter zuverlässigere Ergebnisse liefern.

**Beispiel 5.7** (Transformation des Korrelationskoeffizienten). Sei  $\theta$  der Korrelationskoeffizient. Ein Konfidenzintervall für  $\theta$  können wir auf die folgenden zwei Weisen erhalten:

(i) Bootstrap- $t$ -Intervall für  $\theta$  direkt.

(ii) Bootstrap- $t$ -Intervall für

$$\phi = \frac{1}{2} \log \left( \frac{1 + \theta}{1 - \theta} \right) \quad (\text{Fishersche } Z\text{-Transformation})$$

und dann Rücktransformation der Endpunkte mittels der Umkehrung

$$\theta = \frac{e^{2\phi} - 1}{e^{2\phi} + 1}$$

liefert ein kürzeres (= besseres) Konfidenzintervall als das Intervall in (i).

- Ergebnis:
1. Bootstrap- $t$  nur für einfache Probleme verwenden, wenn  $\theta$  ein Lokalisationsparameter, zum Beispiel Median, trimmed mean oder Quantil ist.
  2. In komplexen Fällen ist eine Varianzstabilisierung notwendig.

### 5.3.3 Bootstrap-Perzentil-Intervall

*Idee:* Verwende direkt die empirische Verteilung der Schätzer  $\hat{\theta}^*$  aus den  $B$  Bootstrap-Stichproben.

*Also:*

1. Ziehe  $x^{*1}, \dots, x^{*B}$   $B$  Bootstrap-Replikationen  
 $\downarrow \qquad \qquad \downarrow$   
 $\hat{\theta}^*(1), \dots, \hat{\theta}^*(B)$  mit  $\hat{\theta}^*(b) = T(x^{*b})$ .

2. Ordne die  $\hat{\theta}^*(b)$  der Größe nach:  $\hat{\theta}_{(1)}^*, \dots, \hat{\theta}_{(B)}^*$ .

3. Berechne  $B\alpha$  und  $B(1 - \alpha)$  (bzw. bei nicht-ganzzahliger Anzahl eine Modifikation wie in Abschnitt 5.3.2) und bezeichne mit  $\hat{\theta}_B^{*(\alpha)}$  bzw.  $\hat{\theta}_B^{*(1-\alpha)}$  die Werte an den jeweiligen Positionen in der sortierten Sequenz der Bootstrap-Schätzungen. Dann ist

$$\left[ \hat{\theta}_{\text{lower}}, \hat{\theta}_{\text{upper}} \right] = \left[ \hat{\theta}_B^{*(\alpha)}, \hat{\theta}_B^{*(1-\alpha)} \right]$$

ein approximatives  $(1 - 2\alpha)$ -Konfidenzintervall.

*Beispiel:* Für  $B = 2000$  und  $\alpha = 0.05$  wähle den 100. und 1900. Wert aus der geordneten Liste.

*Alternative Schreibweise:* Bezeichne mit  $\hat{G}_B$  die empirische Verteilung der  $\hat{\theta}^*$ . Dann ist

$$\left[ \hat{\theta}_{\text{lower}}, \hat{\theta}_{\text{upper}} \right] = \left[ \hat{G}_B^{-1}(\alpha), \hat{G}_B^{-1}(1 - \alpha) \right].$$

*Vorteile der Perzentil-Methode:*

- (i) Sie ist invariant gegenüber (streng monotonen) Transformationen.
- (ii) Sie ist *range-preserving*, d.h. das Perzentil-Intervall liegt im zulässigen Bereich des Parameters.

*Beispiel:* Für den Korrelationskoeffizienten liegt das Intervall der Perzentil-Methode im Bereich  $[-1, 1]$ .

*Problem:* In der Regel Unterdeckung, d.h. die Intervalle sind häufig zu optimistisch.

**Lemma 5.2** (Perzentil-Intervall-Lemma). *Seien  $\phi = m(\theta)$  und  $\hat{\phi} = m(\hat{\theta})$  eindeutige Transformationen. Angenommen,  $\hat{\phi} = m(\hat{\theta})$  normalisiere die Verteilung von  $\hat{\theta}$  perfekt, d.h.*

$$\hat{\phi} \stackrel{\substack{\text{exakt,} \\ \text{nicht nur} \\ \text{approx.}}}{\sim} N(\phi, c^2)$$

*für eine Standardabweichung  $c$ .*

*Dann ist das Perzentil-Intervall basierend auf  $\hat{\theta}$  gleich*

$$\left[ m^{-1}(\hat{\phi} - z^{(1-\alpha)} \cdot c), m^{-1}(\hat{\phi} - z^{(\alpha)} \cdot c) \right]$$

*mit den Quantilen  $z^{(\alpha)}$ ,  $z^{(1-\alpha)}$  der Standardnormalverteilung.*

Das Lemma besagt, dass die Perzentil-Methode immer die korrekte Transformation wählt.

- Diskussion:*
- Die Perzentil-Methode ist sehr einfach.
  - Die Perzentil-Methode ist nicht der Weisheit letzter Schluss. Wenn  $\hat{\theta}$  ein Schätzer mit Bias ist, gibt es Alternativen.