


# Vorlesung 12a

## Schätzen von Parametern


### Teil 2

Unser Logo der ersten Stunde:



$$\mathbf{P} (X \in da) = \rho (da)$$

## Ein Logo der Statistik:



$$\mathbf{P}_{\vartheta}(X \in da) = \rho_{\vartheta}(da), \quad \vartheta \in \Theta$$

$\Theta$  ... *Parameterraum*

$S$  ... *Beobachtungsraum*

$\hat{\vartheta} := t(X)$  ... *Schätzer für den Parameter  $\vartheta$*

Ein tragfähiger Vorschlag für die Schätzung von  $\vartheta$ :

Für jedes  $a \in S$  sei  $t(a)$  dasjenige (oder eines von den)  $\vartheta$ , für das die W'keit, den Ausgang  $a$  zu erhalten, maximal wird.

Für diskretes  $X$  heißt dies:

$$\mathbf{P}_{t(a)}(X = a) = \max_{\vartheta \in \Theta} \mathbf{P}_{\vartheta}(X = a) .$$

M. a. W.:

$t(a)$  ist Maximalstelle von  $\vartheta \mapsto \rho_{\vartheta}(a)$ .

Die Zufallsvariable  $\hat{\vartheta} := t(X)$  nennt man dann

*Maximum-Likelihood-Schätzer*

für den Parameter  $\vartheta$  auf der Basis von  $X$ .

Im Fall von Dichten:

$$\rho_{\vartheta}(da) = f_{\vartheta}(a) da, \quad \vartheta \in \Theta ,$$

nimmt man  $t(a)$  als Maximalstelle von  $\vartheta \mapsto f_{\vartheta}(a)$

## Beispiel 1:

$n$  unabhängige,  $N(\mu, \sigma^2)$ -verteilte Zufallsvariable:

$$\begin{aligned}\vartheta &:= (\mu, \sigma) \mapsto f_{(\mu, \sigma^2)}(a) \\ &= (2\pi\sigma^2)^{-n/2} e^{-((a_1 - \mu)^2 + \dots + (a_n - \mu)^2) / \sigma^2}\end{aligned}$$

hat als Minimalstelle das Zahlenpaar mit den Komponenten

$$\bar{a} := \frac{1}{n}(a_1 + \dots + a_n),$$

$$\sqrt{\frac{1}{n}((a_1 - \bar{a})^2 + \dots + (a_n - \bar{a})^2)}.$$

Fazit:

Seien  $X_1, \dots, X_n$  unabhängig und  $N(\mu, \sigma^2)$ -verteilt.


Der ML-Schätzer für  $\vartheta = (\mu, \sigma)$  ist dann  $(\hat{\mu}, \hat{\sigma})$  mit

$$\hat{\mu} := \frac{1}{n}(X_1 + \dots + X_n),$$

$$\hat{\sigma}^2 := \frac{1}{n}((X_1 - \hat{\mu})^2 + \dots + (X_n - \hat{\mu})^2) .$$

(vgl. Buch Seite 124)

Beispiel 2:  
Die einfache lineare Regression





$x_1, \dots, x_n$  sind feste reelle Zahlen, und das Modell ist

$$Y_i = \beta_0 + \beta_1 x_i + \sigma Z_i, \quad i = 1, \dots, n,$$

mit  $\beta_0, \beta_1 \in \mathbb{R}, \sigma > 0$ .

Die  $Z_i$  sind gedacht als unabhängige,  
standard-normalverteilte ZV'e.

Das Modell lässt sich in vektorieller Form schreiben:

Sei  $e := (1, \dots, 1)$  und  $x := (x_1, \dots, x_n)$


$$Y = \beta_0 e + \beta_1 x + \sigma Z$$

= **systematische Komponente** + **Rauschen**

$$= \mu + \sigma Z$$

mit  $\mu \in K :=$  der von  $e$  und  $x$  aufgespannte Teilraum von  $\mathbb{R}^n$

(Dies ist ein Beispiel eines *normalen Linearen Modells*.)



Als Maximum-Likelihood-Schätzer für  $(\mu, \sigma^2)$  ergibt sich

$$\hat{\mu} := \mathcal{P}_K Y, \quad \hat{\sigma}^2 := |\mathcal{P}_{K^\perp} Y|^2 / n.$$

Berechnung der Koeffizienten  $\hat{\beta}_0$  und  $\hat{\beta}_1$  in der Projektion

$$\mathcal{P}_K Y = \hat{\beta}_0 e + \hat{\beta}_1 x :$$

Wir verwenden als Orthonormalbasis von  $K$ :

$$b := \frac{1}{\sqrt{n}}e, \quad b' := \frac{x - \bar{x}e}{|x - \bar{x}e|}.$$

$$\mathcal{P}_K Y = \langle Y, b \rangle b + \langle Y, b' \rangle b' = \bar{Y}e + \frac{\langle Y - \bar{Y}e, x - \bar{x}e \rangle}{|x - \bar{x}e|^2} (x - \bar{x}e).$$

Berechnung der Koeffizienten  $\hat{\beta}_0$  und  $\hat{\beta}_1$  in der Projektion

$$\mathcal{P}_K Y = \hat{\beta}_0 e + \hat{\beta}_1 x :$$

Wir verwenden als Orthonormalbasis von  $K$ :

$$b := \frac{1}{\sqrt{n}}e, \quad b' := \frac{x - \bar{x}e}{|x - \bar{x}e|}.$$

$$\mathcal{P}_K Y = \langle Y, b \rangle b + \langle Y, b' \rangle b' = \bar{Y}e + \frac{\langle Y - \bar{Y}e, x - \bar{x}e \rangle}{|x - \bar{x}e|^2} (x - \bar{x}e).$$

Also ergeben sich die  $x$ - und  $e$ -Koordinaten von  $\mathcal{P}_K Y$  als:

$$\hat{\beta}_1 = \frac{\langle Y - \bar{Y}e, x - \bar{x}e \rangle}{|x - \bar{x}e|^2} = \frac{\sum_{i=1}^n (Y_i - \bar{Y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2},$$

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{x}.$$

Berechnung der Koeffizienten  $\hat{\beta}_0$  und  $\hat{\beta}_1$  in der Projektion

$$\mathcal{P}_K Y = \hat{\beta}_0 e + \hat{\beta}_1 x :$$

Wir verwenden als Orthonormalbasis von  $K$ :


$$b := \frac{1}{\sqrt{n}}e, \quad b' := \frac{x - \bar{x}e}{|x - \bar{x}e|}.$$

$$\mathcal{P}_K Y = \langle Y, b \rangle b + \langle Y, b' \rangle b' = \bar{Y}e + \frac{\langle Y - \bar{Y}e, x - \bar{x}e \rangle}{|x - \bar{x}e|^2} (x - \bar{x}e).$$

Also ergeben sich die  $x$ - und  $e$ -Koordinaten von  $\mathcal{P}_K Y$  als:

$$\hat{\beta}_1 = \frac{\langle Y - \bar{Y}e, x - \bar{x}e \rangle}{|x - \bar{x}e|^2} = \frac{\sum_{i=1}^n (Y_i - \bar{Y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2},$$

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{x}.$$



Die Gerade  $x \mapsto y = \hat{\beta}_0 + \hat{\beta}_1 x$  heißt *Regressionsgerade*.

Ihr Anstieg ist der *Regressionskoeffizient*  $\hat{\beta}_1$ .

Sie geht durch den zentralen Punkt  $(\bar{x}, \bar{Y})$ .

Man beachte die Analogie zum Beispiel am Ende von Vorlesung 7a.

## Maximum-Likelihood-Schätzer am Beispiel des Münzwurfs:

$(X_1, \dots, X_n)$  sei  $p$ -Münzwurf mit unbekanntem  $p$

Beobachtet wird die Realisierung  $(a_1, \dots, a_n)$

mit  $k = a_1 + \dots + a_n$ .

Unter allen  $p$  ist  $k/n$  derjenige Parameter, mit dem

$$\mathbf{P}_p(X_1 = a_1, \dots, X_n = a_n) = p^k (1 - p)^{n-k}$$

maximal ist.

Man sagt:

$$\hat{p} := \frac{1}{n}(X_1 + \dots + X_n)$$

ist der Maximum-Likelihood-Schätzer für  $p$ .



Für  $k = 0$  (kein Erfolg in  $n$  Versuchen) ergibt sich 0  
als Maximum-Likelihood-Schätzung von  $p$ .

Das ist möglicherweise zu pessimistisch.

Eine Alternative bietet der sogenannte *Bayes-Schätzer*  
(vgl Buch S. 127).

Hier denkt man an ein zweistufiges Experiment:

1. eine auf  $[0, 1]$  uniform verteilte Zufallsvariable  $U$
2. gegeben  $\{U = u\}$  einen Münzwurf mit  
Erfolgswahrscheinlichkeit  $U$ .

$$\tilde{p} := \mathbf{E}[U|K_n] .$$

Erinnerung an Vorlesung 9b:

$Z_1, Z_2, \dots$  sei ein Münzwurf mit uniform auf  $[0, 1]$  verteiltem zufälligem Erfolgsparameter  $U$ ,

$K_n$  sei die Anzahl der Erfolge in den ersten  $n$  Versuchen.

Gefragt ist nach  $\mathbf{E}[U \mid K_n = k]$ .

Wir wissen schon:

Die bedingte Dichte von  $U$  gegeben  $\{K_n = k\}$  ist

$$\mathbf{P}_k(U \in du) = \frac{1}{\frac{1}{n+1}} \binom{n}{k} u^k (1-u)^{n-k} du$$

$$\begin{aligned}
\mathbf{E}[U \mid K_n = k] &= \int \frac{1}{\frac{1}{n+1}} \binom{n}{k} u^{k+1} (1-u)^{n-k} du \\
&= \frac{k+1}{n+2} \int \frac{1}{\frac{1}{n+2}} \binom{n+1}{k+1} u^{k+1} (1-u)^{(n+1)-(k+1)} du \\
&= \frac{k+1}{n+2}.
\end{aligned}$$

Man nennt dies auch den

**Bayes-Schätzer für die Erfolgswahrscheinlichkeit**

(bei a priori uniform verteilter Erfolgswahrscheinlichkeit).

Man muss hier gar nicht rechnen. Mit der totalen W'keit gilt:

$$\mathbf{E}[U | K_n] = \mathbf{E}[\mathbf{P}[Z_{n+1} = 1 | U] | K_n] = \mathbf{P}[Z_{n+1} = 1 | K_n]$$

Im Buch S. 113/114 liest man nach  
(vgl. dazu auch unsere Übungsaufgabe 36):

Ein Münzwurf  $(Z_1, Z_2, \dots)$

mit uniform verteilter Erfolgswahrscheinlichkeit  $U$

ist so verteilt wie die Folge der Zuwächse in Richtung Osten

in einer Nordost-Wanderung à la Pólya. Also:

$$\mathbf{P}[Z_{n+1} = 1 | K_n = k] = \frac{k + 1}{n + 2}.$$

Die nächsten beiden Folien zeigen einen Vergleich der Überdeckungsw'keiten der beiden Konfidenzintervalle


$$I := \left( \hat{p} - 2\sqrt{\frac{1}{n}\hat{p}(1 - \hat{p})}, \hat{p} + 2\sqrt{\frac{1}{n}\hat{p}(1 - \hat{p})} \right) := (\hat{p} \pm 2\hat{\sigma})$$

und


$$\tilde{I} := \left( \tilde{p} - 2\sqrt{\frac{1}{n}\tilde{p}(1 - \tilde{p})}, \tilde{p} + 2\sqrt{\frac{1}{n}\tilde{p}(1 - \tilde{p})} \right) := (\tilde{p} \pm 2\tilde{\sigma})$$

(siehe dazu Buch Seite 129/130)

$$H := \{ p \in (\hat{p} \pm 2\hat{\sigma}) \}$$



$$J := \{ p \in (\tilde{p} \pm 2\tilde{\sigma}) \}$$

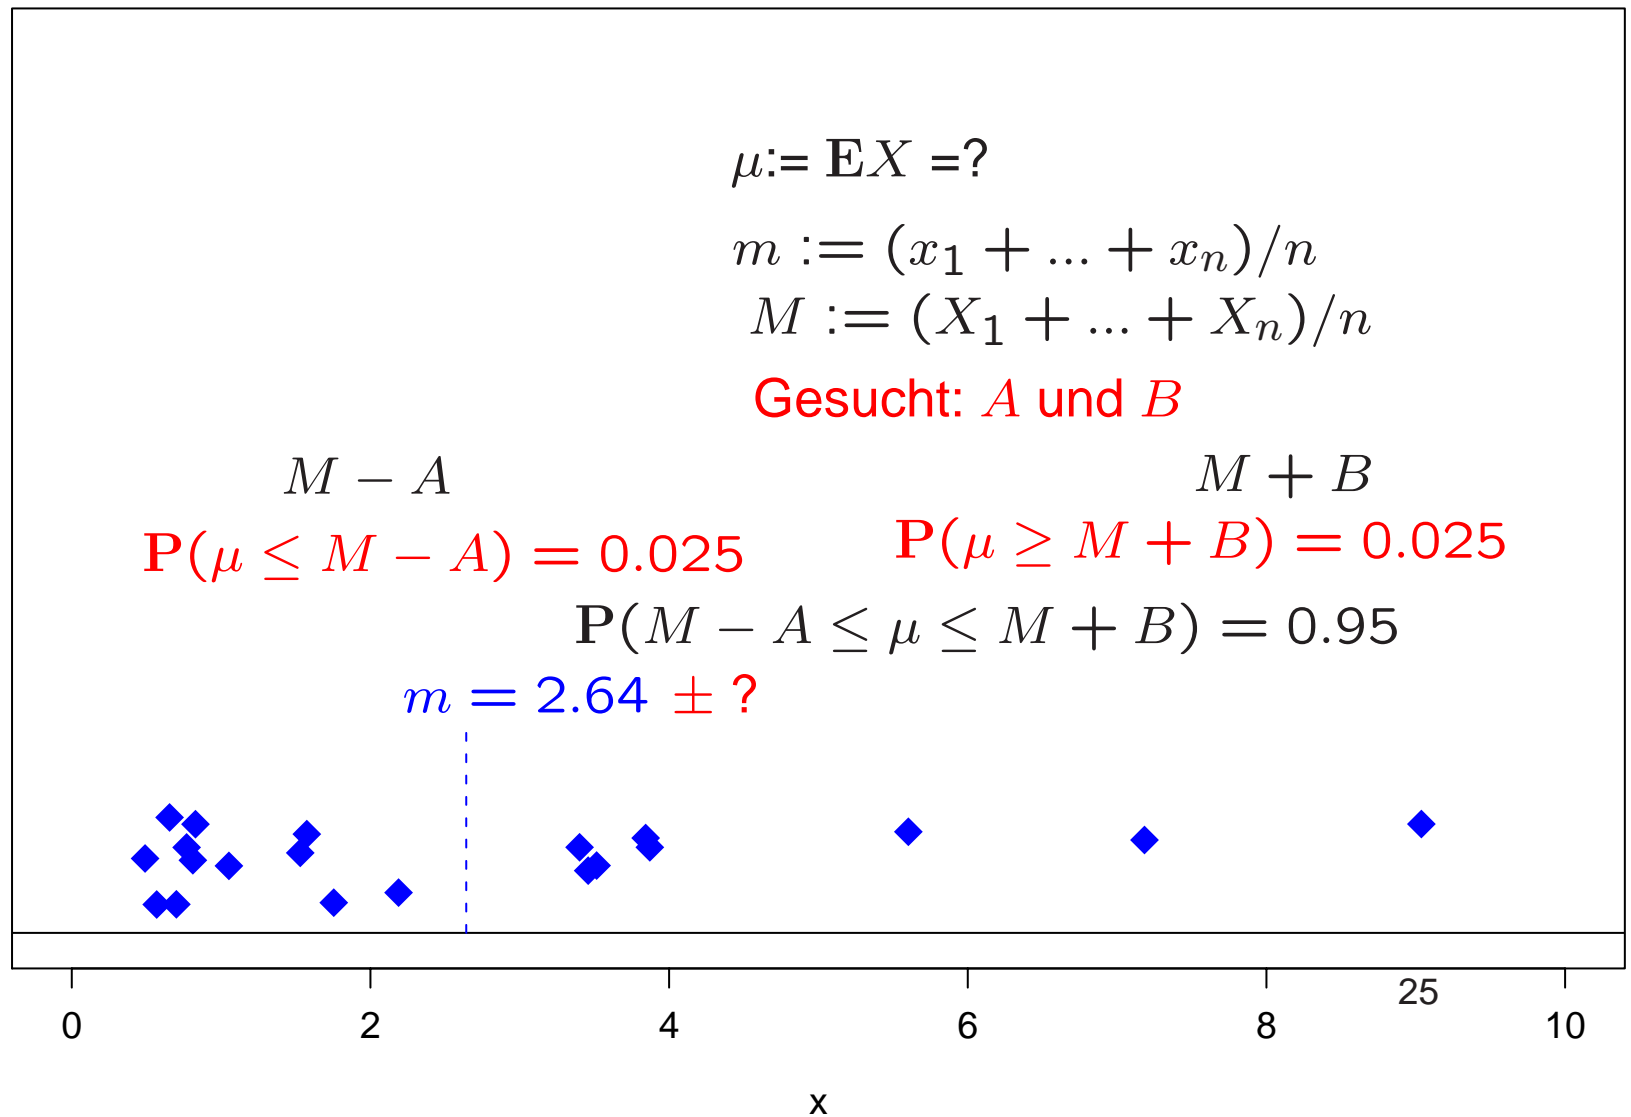


## **Die Idee des Bootstrap**

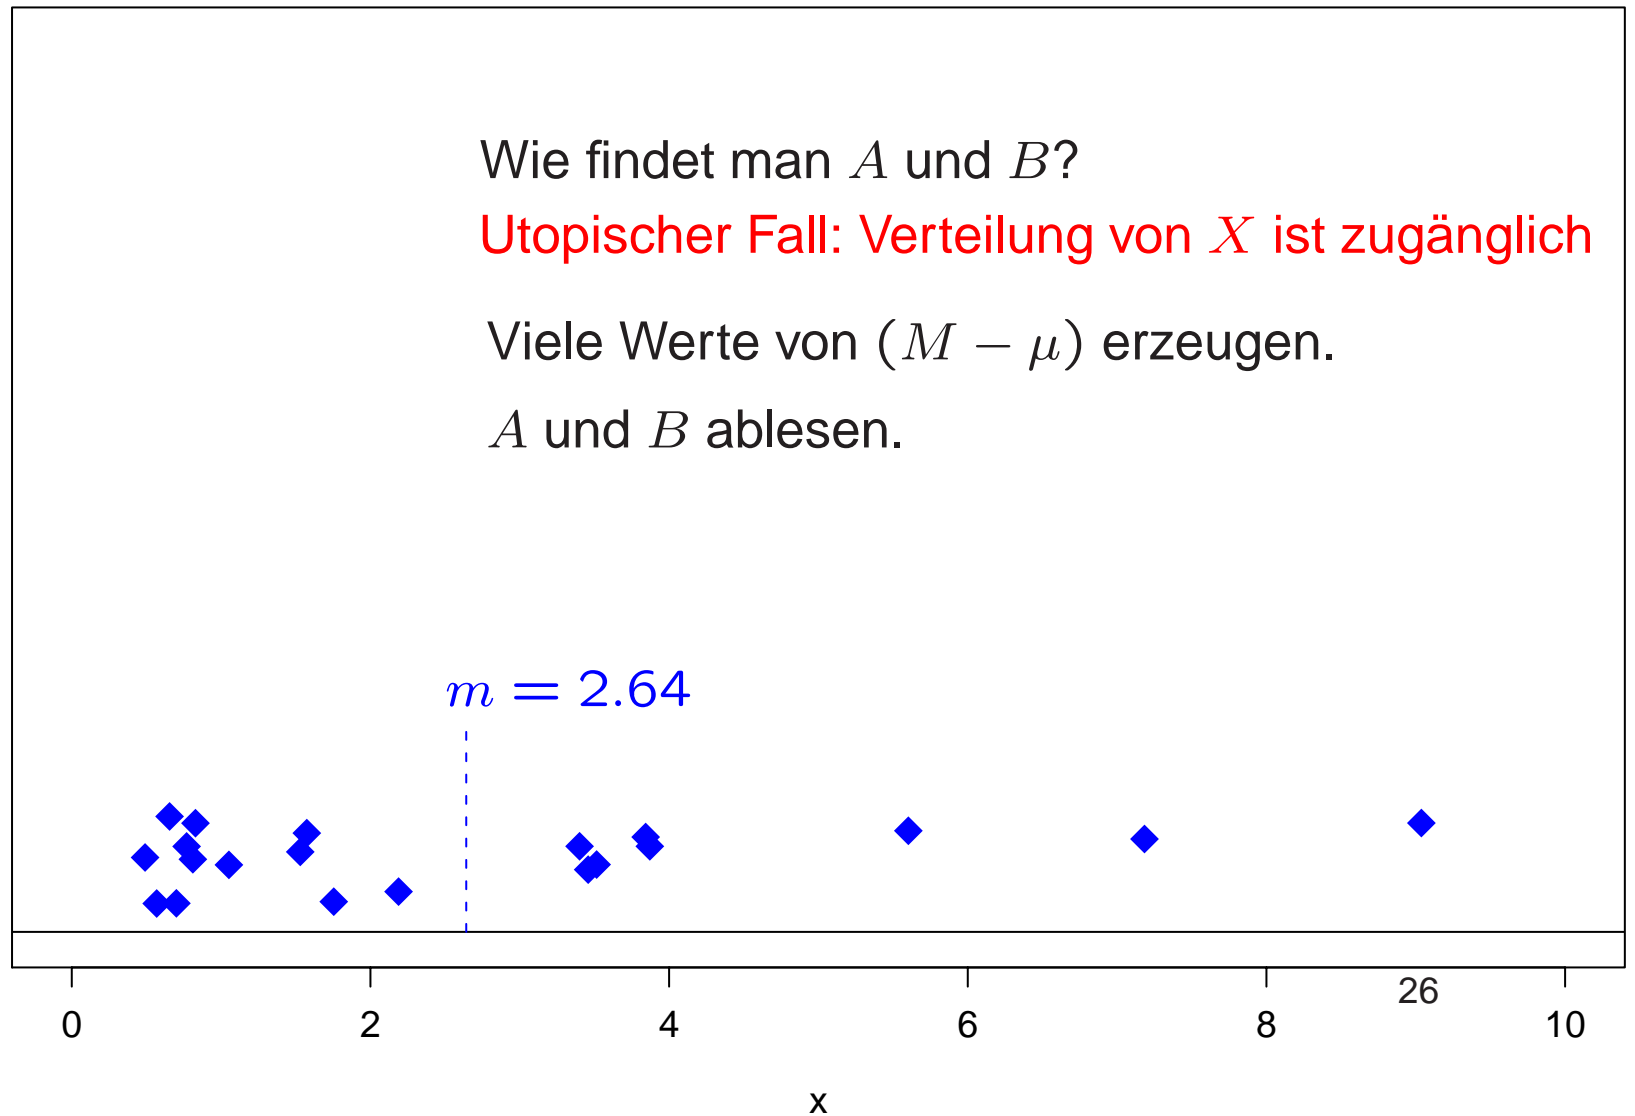
am Beispiel eines Bootstrap-Konfidenzintervalls  
für den Erwartungswert




Beobachtungen  $x_1, \dots, x_n$  der Zufallsgröße  $X$  ( $n = 20$ )



Beobachtungen  $x_1, \dots, x_n$  der Zufallsgröße  $X$  ( $n = 20$ )




Utopie: 1000 Beobachtungen von  $M - \mu$



# Utopie

$\nu :=$  die Verteilung von  $X$   
Mit Stichproben aus  $\nu$   
könnte man  $A$  und  $B$  schätzen  
 $\nu$  ist unbekannt. Was tun?



## Strecken nach der Decke

$\nu :=$  die Verteilung von  $X$

Mit Stichproben aus  $\nu$

könnte man  $A$  und  $B$  schätzen

$\nu$  ist unbekannt. Was tun?

$$\nu_{\vec{x}} := \frac{1}{n}(\delta_{x_1} + \dots + \delta_{x_n})$$

die geschätzte Verteilung von  $X$

Bootstrap-Heuristik


$$\nu \sim \nu_{\vec{x}}$$

Also: **Stichproben**


aus  $\nu_{\vec{x}}$  liefern  $(A^*, B^*)$

Bootstrap-Konfidenzintervall


$$(m - A^*, m + B^*)$$




Utopisch: 1000 Realisierungen von  $M - \mu$  aus der unbekanntem Verteilung



Praktisch: 1000 Realisierungen von  $(M^* - m)$  aus Bootstrap-Stichproben



# Bootstrap Konfidenzintervall





## Überdeckungswahrscheinlichkeit


Mit welcher W'keit überdeckt das zufällige Intervall  
den wahren Parameter?

Hoffentlich mit annähernd 95 %.


Wie können wir das prüfen?

Wir ziehen 1000 Stichproben  $\vec{x}_1, \dots, \vec{x}_{1000}$   
und beschaffen uns für jedes  $i = 1, \dots, 1000$   
durch 1000 Zwanziger-Züge aus  $\nu_{\vec{x}_i}$   
eine Realisierung des Konfidenzintervalls  
 $[U_i, O_i] := [M_i - A_i^*, M_i + B_i^*]$


# Neue Stichprobe



# Neue Stichprobe



# Neue Stichprobe



37


10

Wir ziehen 1000 Stichproben  $\vec{x}_1, \dots, \vec{x}_{1000}$   
und beschaffen uns für jedes  $i = 1, \dots, 1000$   
durch 1000 Zwanziger-Züge aus  $\nu_{\vec{x}_i}$   
eine Realisierung des Konfidenzintervalls

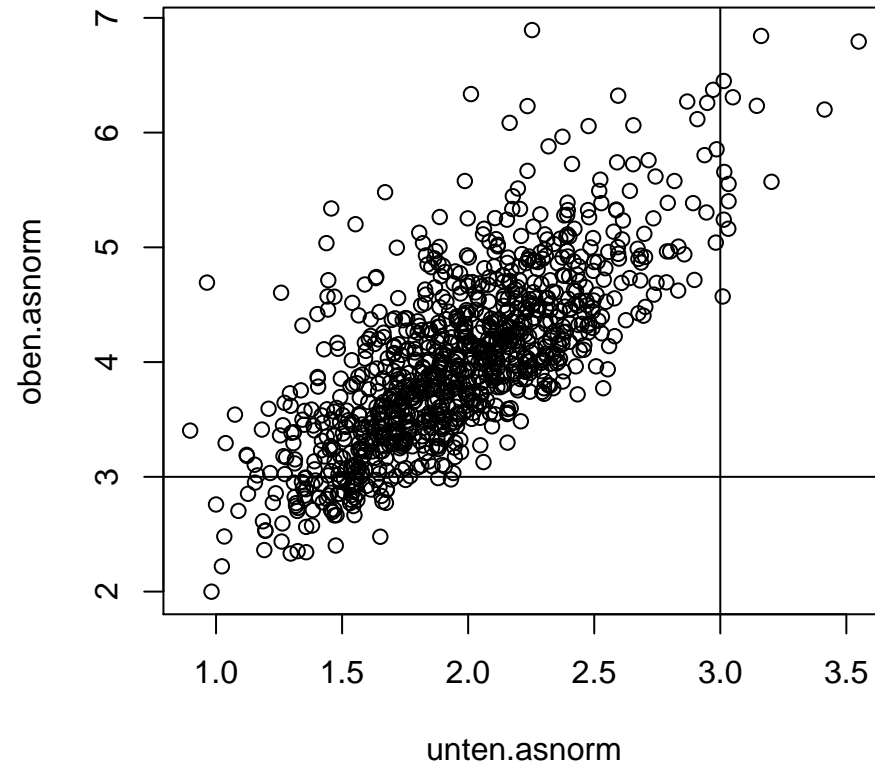
$$[U_i, O_i] := [M_i - A_i^*, M_i + B_i^*]$$

Jedes der Paare  $(U_i, O_i)$  wird dargestellt als Punkt im  $\mathbb{R}^2$ .

Das Intervall  $[U_i, O_i]$  überdeckt  $\mu = 3 \iff$   
der Punkt  $(U_i, O_i)$  liegt im Quadranten  $\{(x, y) \mid x \leq 3, y \geq 3\}$



897 von 1000 Realisierungen des *einfachen Bootstrap-Konfidenzintervalls*  
 $(m - A^*, m + B^*)$  haben  $\mu$  überdeckt



904 von 1000 Realisierungen des *normalen Konfidenzintervalls*  
 $[M - (1.96/\sqrt{n})s, M + (1.96/\sqrt{n})s]$  haben  $\mu$  überdeckt