

# Vorlesung 12a

## Schätzen mit Verlass

Beispiele von Konfidenzintervallen

# 1. Schätzen von Anteilen

Große Population ( $\text{♀}$  und  $\text{♂}$ )  
mit unbekanntem Weibchenanteil  $p$

In einer Stichprobe vom Umfang  $n = 53$   
gab es 23 Weibchen.

Wie zuverlässig ist  $\frac{23}{53}$  als Schätzung für  $p$  ?

## Goldene Idee der Statistik:

In einem idealisiert gedachten Szenario interpretiert man den Schätzwert als Realisierung einer Zufallsvariablen und rechnet mit deren Variabilität.

Deutung der Stichprobenziehung als  $p$ -Münzwurf

Als *Schätzer* für  $p$  betrachten wir die *Zufallsvariable*

$$\hat{p} := H := \frac{K}{n}, \quad \text{mit } K := \text{Anzahl der "Erfolge".}$$

$H$  ist die (relative) Häufigkeit der Erfolge.

$$\sigma_H = ?$$

$K$  ist  $\text{Bin}(n, p)$ -verteilt. Also:

$$\sigma_H = \frac{1}{\sqrt{n}} \sqrt{p(1-p)}$$

Der Zentrale Grenzwertsatz besagt:

$H$  ist approximativ normalverteilt

mit Erwartungswert  $\mu_H = p$  und Standardabweichung  $\sigma_H$ .

Also insbesondere:

$$\mathbf{P}_p(|p - H| \leq 2\sigma_H) \approx 0.95$$

$$\mathbf{P}_p(p \in [H - 2\sigma_H, H + 2\sigma_H]) \approx 0.95$$

In der Praxis ist auch  $\sigma_H$   
(aus der *einen* vorliegenden Stichprobe) zu schätzen.

Als Schätzer für  $\sigma_H = \frac{1}{\sqrt{n}}\sqrt{p(1-p)}$  bietet sich an:

$$\widehat{\sigma}_H := \frac{1}{\sqrt{n}}\sqrt{H(1-H)}$$

$$\mathbf{P}_p(p \in [H - 2\sigma_H, H + 2\sigma_H]) \approx 0.95$$

überträgt sich auf

$$\mathbf{P}_p(p \in [H - 2\widehat{\sigma}_H, H + 2\widehat{\sigma}_H]) \approx 0.95$$

Das zufällige Intervall

$$I := [H - 2\widehat{\sigma}_H, H + 2\widehat{\sigma}_H]$$

ist ein

Konfidenzintervall für  $p$

mit approximativer Überdeckungswahrscheinlichkeit 0.95

oder kurz ein

approximatives 95%-Konfidenzintervall für  $p$ .



In unserem Eingangsbeispiel ( $n = 53, k = 23$ )  
hatten die beobachteten Realisierungen von  $H$  und  $\widehat{\sigma}_H$   
die Werte

$$h = 23/53 = 0.43,$$
$$\frac{1}{\sqrt{n}}\sqrt{h(1-h)} = \sqrt{\frac{0.43 \cdot 0.57}{53}} = 0.07.$$

Als Realisierung von  $I = [H - 2\widehat{\sigma}_H, H + 2\widehat{\sigma}_H]$  ergab sich  
 $[0.43 - 2 \cdot 0.07, 0.43 + 2 \cdot 0.07] = [0.29, 0.57]$ .

Man beachte:

Nicht der Parameter  $p$  ist zufällig, sondern das Intervall  $I$ .

Im Jargon der Statistik wird oft sowohl der Schätzer (die Zufallsvariable)  $H$  als auch der Schätzwert (die Zahl)  $h$  mit dem Symbol  $\hat{p}$  bezeichnet.

Auf der nächsten Folie,  
die das Obige zusammenfasst,  
steht  $\hat{p}$  für die Zufallsvariable  $H$   
(vgl. Buch S. 122):

Das zufällige Intervall

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

ist ein

Konfidenzintervall für  $p$

mit approximativer Überdeckungswahrscheinlichkeit 0.95

oder kurz ein

approximatives 95%-Konfidenzintervall für  $p$ .

Dabei sollte  $np(1 - p)$  “nicht zu klein” sein.

Eine Faustregel für die Anwendbarkeit ist:  $nh \geq 9$  und  $n(1 - h) \geq 9$ .

## 2. Schätzung des Erwartungswertes einer Verteilung auf $\mathbb{R}$ (Lageschätzung)

$$m := \frac{1}{n}(x_1 + \dots + x_n)$$

wird gedacht als eine Realisierung der Zufallsvariablen

$$\bar{X} := \frac{1}{n}(X_1 + \dots + X_n)$$

mit  $X_1, \dots, X_n$  unabhängig, identisch verteilt

mit Erwartungswert  $\mu$  und Standardabweichung  $\sigma$ .

Anders als bei der Anteilsschätzung ist hier  $\sigma$  i.a. keine Funktion von  $\mu$ .

$\bar{X}$  ist ein Schätzer für  $\mu$ .

$\bar{X}$  hat Erwartungswert  $\mu$  und Standardabweichung  $\sigma/\sqrt{n}$ .

Ein Schätzer für  $\sigma^2$  ist

$$S^2 := \frac{1}{n-1} \left( (X_1 - \bar{X})^2 + \dots + (X_n - \bar{X})^2 \right)$$

Im Jargon der Statistik schreibt man meist  $s^2$  statt  $S^2$  und verwendet  $s^2$  auch zur Bezeichnung von Schätzwerten (Realisierungen).

Der Zentrale Grenzwertsatz besagt:

$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$  ist approximativ  $N(0, 1)$ -verteilt.

Bei bekanntem  $\sigma$  ist also für große  $n$

$$\left[ \bar{X} - 2\frac{\sigma}{\sqrt{n}}, \bar{X} + 2\frac{\sigma}{\sqrt{n}} \right]$$

ein approximatives 95%-Konfidenzintervall für  $\mu$ .

In der Praxis hat man auch  $\sigma$  aus den Daten zu schätzen.

Für große  $n$  ist auch

$$J := \left[ \bar{X} - 2 \frac{S}{\sqrt{n}}, \bar{X} + 2 \frac{S}{\sqrt{n}} \right]$$

ein approximatives 95%-Konfidenzintervall für  $\mu$

Dieses Intervall enthält keine unbekannt Parameter.

Seine Realisierung ist  $[\bar{x} - 2f, \bar{x} + 2f]$ .

Der *Standardfehler*

$$f := \frac{s}{\sqrt{n}}$$

ist ein Schätzwert für die

Standardabweichung  $\sigma/\sqrt{n}$  des Stichprobenmittelwertes  $\bar{X}$ .



Der Zentrale Grenzwertsatz besagt:

$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$  ist approximativ  $N(0, 1)$ -verteilt.

Bei bekanntem  $\sigma$  ist also

$$\left[ \bar{X} - \frac{2\sigma}{\sqrt{n}}, \bar{X} + \frac{2\sigma}{\sqrt{n}} \right]$$

ein approximatives 95%-Konfidenzintervall für  $\mu$ .

In der Praxis hat man auch  $\sigma$  aus den Daten zu schätzen.

Für (einigermaßen) große  $n$  ist auch

$$\left[ \bar{X} - \frac{2S}{\sqrt{n}}, \bar{X} + \frac{2S}{\sqrt{n}} \right]$$

ein approximatives 95%-Konfidenzintervall für  $\mu$ .

Für kleine  $n$  (etwa:  $n \leq 10$ ) und (exakt bzw. annähernd)  
normalverteilte  $X_i$

macht man sich zunutze, dass die Verteilung von  
 $T := \frac{\sqrt{n}(\bar{X} - \mu)}{S}$  (exakt bzw. annähernd) so verteilt ist wie

$$T_{n-1} := \frac{N_0}{\sqrt{\frac{1}{n-1} (N_1^2 + \dots + N_{n-1}^2)}}$$

mit unabhängigen und  $N(0, 1)$  verteilten  $N_0, \dots, N_{n-1}$ .

Satz (W. Gosset (alias “Student”, 1908), R. Fisher (1924))

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

dann ist  $T := \frac{\sqrt{n}(\bar{X} - \mu)}{S}$  so verteilt wie


$$T_{n-1} := \frac{N_0}{\sqrt{\frac{1}{n-1} (N_1^2 + \dots + N_{n-1}^2)}}$$

mit unabhängigen und  $N(0, 1)$  verteilten  $N_0, \dots, N_{n-1}$ .

Diese Tatsache lässt sich aus der Rotationssymmetrie der  $n$ -dimensionalen Standard-Normalverteilung gut verstehen, siehe Buch S.138/139

Bezeichnung: Die Verteilung von  $T_{n-1}$  heißt  **$t$ -Verteilung** (oder **Student-Verteilung**) mit  $n - 1$  Freiheitsgraden.

## Student's t: Dichtefunktionen



df ( $= n - 1$ ) steht hier für “degrees of freedom”, d.h. “Freiheitsgrade”

$$T_{n-1} := \frac{N_0}{\sqrt{\frac{1}{n-1} (N_1^2 + \dots + N_{n-1}^2)}}$$

Für  $n \rightarrow \infty$  ist  $T_{n-1}$  asymptotisch  $N(0, 1)$ -verteilt  
(Gesetz der großen Zahlen für den Nenner von  $T_{n-1}$ ).

Je kleiner  $n$ , um so mehr schwankt der Nenner, und  
um so *breitschultriger* ist die Verteilung von  $T_{n-1}$

Z.B. für  $n = 6$ :  $\mathbf{P}(|T_5| \leq 2.57) = 0.95$ .

Der passende R-Befehl ist `qt(0.975, 5)`,  
mit der Ausgabe 2.57

Denn:  $\mathbf{P}(T_5 \leq 2.57) = 0.975$ .

Man sagt:

Das 0.975-Quantil der  $t(5)$ -Verteilung ist 2.57.

Eine direkte Folgerung aus dem Satz von Gosset-Fisher:

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

dann ist für jedes  $c > 0$ :

$$\mathbf{P}\left(\mu \in \left[\bar{X} - \frac{cS}{\sqrt{n}}, \bar{X} + \frac{cS}{\sqrt{n}}\right]\right) \\ \mathbf{P}\left(\left|\frac{\sqrt{n}(\bar{X} - \mu)}{S}\right| \leq c\right) = \mathbf{P}(|T_{n-1}| \leq c).$$

Damit  $\left[\bar{X} - \frac{cS}{\sqrt{n}}, \bar{X} + \frac{cS}{\sqrt{n}}\right]$   
ein 95%-Konfidenzintervall für  $\mu$  ist,

bestimme also  $c$  so,

dass  $\mathbf{P}(|T_{n-1}| \leq c) = 0.95$  gilt.

Z.B. für  $n = 6$ :  $\mathbf{P}(|T_5| \leq 2.57) = 0.95$ .

Ein 95%-Konfidenzintervall für  $\mu$  ist somit hier gegeben

durch

$$\left[ \bar{X} - 2.57 \frac{S}{\sqrt{n}}, \bar{X} + 2.57 \frac{S}{\sqrt{n}} \right]$$

2.57 ist deutlich größer als das aus dem Fall großer  $n$  vertraute 2  
(siehe Folie 16).

Die zusätzliche, durch die Schwankungen des Schätzers  $S$   
verursachte Variabilität wird durch  
die passende Verlängerung des Intervalls kompensiert.

### 3. Schätzung des Medians einer Verteilung\*

\*Nachgetragen in der Vorlesung am 05.01.2019



Seien  $X_1, X_2, \dots, X_n$  unabhängig, mit Verteilung  $\rho$ .  
Es gibt Situationen, in denen die Schätzung der “Lage” von  $\rho$   
über den Stichprobenmittelwert problematisch ist –  
etwa wenn  $\rho$  so viel Masse weit draußen hat,  
dass die Varianz von  $\rho$  sehr groß ist  
(oder sogar der Erwartungswert von  $\rho$  gar nicht existiert)

In diesem Fall ist es günstig,  
einen “robusteren” Lageschätzer zu verwenden:

## Definition.

Eine Zahl  $\nu$  heißt *Median* der Verteilung  $\rho$  auf  $\mathbb{R}$ ,  
wenn  $\rho((-\infty, \nu]) \geq 1/2$  **und**  $\rho([\nu, \infty)) \geq 1/2$  gilt.

Wenn es nur eine Zahl  $\nu$  gibt mit  $\rho((-\infty, \nu]) = 1/2$   
(also z. B. wenn  $\rho([\ell, r]) = 1$  gilt  
und  $\rho$  eine strikt positive Dichtefunktion besitzt),  
dann ist  $\nu$  **der** Median von  $\rho$ .

## Definition.

Eine Zahl  $\nu$  heißt *Median* der Verteilung  $\rho$  auf  $\mathbb{R}$ ,  
wenn  $\rho((-\infty, \nu]) \geq 1/2$  **und**  $\rho([\nu, \infty)) \geq 1/2$  gilt.

Wenn es mehrere Zahlen  $\nu$  gibt mit  $\rho((-\infty, \nu]) = 1/2$ ,  
dann ist jede dieser Zahlen **ein** Median von  $\rho$ .

Bsp: Für die uniforme Verteilung auf  $[0, 1] \cup [2, 3]$   
ist jedes  $\nu \in [1, 2]$  ein Median.

Wie schätzt man den Median?

Die *Ordnungsstatistiken*  $X_{(1)} \leq \dots \leq X_{(n)}$   
sind die aufsteigend geordneten  $X_1, \dots, X_n$ .

Ein Kandidat für ein **Konfidenzintervall für den Median** ist

$$[X_{(1+j)}, X_{(n-j)}]$$

mit  $0 \leq j < n/2$ .

$$\mathbf{P}_\rho(\nu \notin [X_{(1)}, X_{(n)}]) = \mathbf{P}_\rho(X_{(1)} > \nu) + \mathbf{P}_\rho(X_{(n)} < \nu) .$$

$$\mathbf{P}_\rho(X_{(1)} > \nu) \leq 2^{-n}$$

$$\mathbf{P}_\rho(X_{(n)} < \nu) \leq 2^{-n} .$$

Also:

$$\mathbf{P}_\rho(\nu \in [X_{(1)}, X_{(n)}]) \geq 1 - \frac{1}{2^{n-1}} .$$

$$\mathbf{P}_\rho(\nu \in [X_{(1)}, X_{(n)}]) \geq 1 - \frac{1}{2^{n-1}}.$$

Bsp:  $n = 6$

$$\mathbf{P}_\rho(\nu \in [X_{(1)}, X_{(6)}]) \geq 1 - \frac{1}{32} = 0.97 :$$

Das Konfidenzintervall  $[X_{(1)}, X_{(6)}]$  für den Median hält die Überdeckungswahrscheinlichkeit 0.97 ein.

Mit ähnlichen Überlegungen lässt sich zeigen:

$$\mathbf{P}_\rho(\nu \in [X_{(1+j)}, X_{(n-j)}]) \geq 1 - 2\mathbf{P}(Y \leq j)$$

mit  $Y$  Bin( $n, 1/2$ )-verteilt.

Man beachte:

Mit wachsendem  $j$  wird das Intervall kürzer  
und die Überdeckungsw'keit nimmt ab!