

# Analytische Statistik

## Statistische Schätzungen, Konfidenz

László Smeller

## Statistische Schätzungen



## Analytische Statistik

(induktive o. schließende Statistik)



Population  
N = „unendlich“



Stichprobe  
n = endlich

Theoretische Verteilung  
Erwartungswert  
Theoretische Streuung



Häufigkeitsverteilung  
Durchschnitt  
Standardabweichung


## Aufgabe der Schätztheorie

Aus einer Stichprobe Schätzwerte für

- Wahrscheinlichkeiten
- Erwartungswert
- Streuung
- oder andere Parametern einer Verteilung zu ermitteln.


Typen der Schätzungen:

- **Punktschätzung**
- **Intervallschätzung**



## Punktschätzungen

Wir wollen jetzt die Parameter einer Verteilung (z.B.:  $\mu, \sigma$ ) aus den konkreten Werten  $x_1, \dots, x_n$  einer Stichprobe „möglichst gut“ bestimmen, d.h. einen „Näherungswert“ errechnen.



Kriterien:

Erwartungstreue (unverzerrt)	Erwartungswert der Schätzwerte = zu schätzender Parameter
Konsistenz	$n \uparrow \Rightarrow$ bessere Schätzung
Effizienz (wirksam)	kleine Streuung
Exhaustivität (erschöpfend)	berücksichtigt alle Informationen


## Punktschätzungen

Der Parameter wird mit **einem Wert** geschätzt.

### Relative Häufigkeit

ist ein Schätzwert für die **Wahrscheinlichkeit**


Siehe Definition der statistischen Wahrscheinlichkeit!



## Punktschätzungen


### Durchschnitt

ist ein Schätzwert  
für den **Erwartungswert**



### Standardabweichung

ist ein Schätzwert  
für die **theoretische Streuung**



Punktschätzungen sagen

**nichts** über die *Genauigkeit bzw. Sicherheit*  
der Schätzung



## Intervallschätzungen

Intervallschätzung oder Konfidenzschätzung gibt zu einer vorgewählten Sicherheitswahrscheinlichkeit  $\gamma$ , (Konfidenzniveau) ein Intervall  $(c_1, c_2)$  an, in dem der unbekannte Parameter (zB.  $\mu$  oder  $\sigma$ ) mit einer Wahrscheinlichkeit von mindestens  $\gamma$  liegt.



Zb.: Erwartungswert der Pulszahl ist bei  
95% Konfidenzniveau:  $(74 \pm 6)^{1/Min}$

$\alpha = 1 - \gamma$  Irrtumswahrscheinlichkeit

## Intervallschätzungen

Wie große  $\gamma$  Sicherheitswahrscheinlichkeit (Konfidenzniveau) soll gewählt werden?

Wichtige Faktoren:

- Streuung der Daten
- Stichprobenumfang
- Größe der Schaden bei einer falschen Schätzung

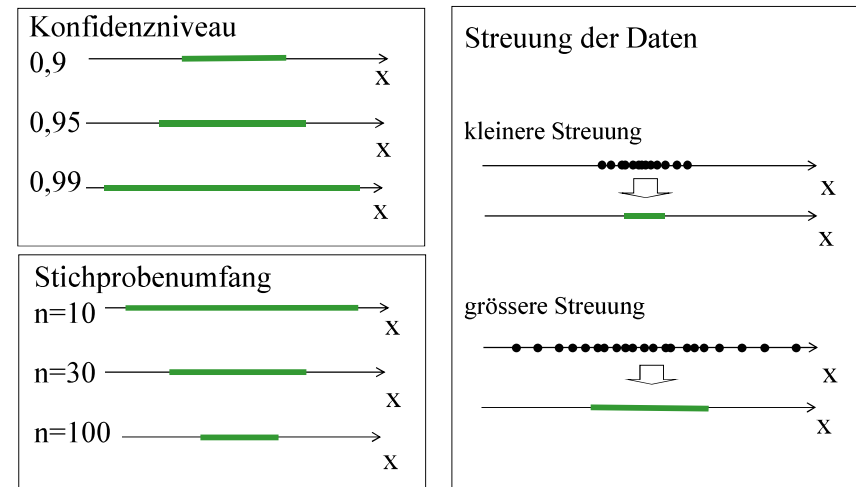
Sozialwissenschaft  $\gamma=0,9$

Medizin  $\gamma=0,95$

Technik  $\gamma=0,99$

9

Einfluss des Konfidenzniveaus, der Streuung und des Stichprobenumfanges auf die Breite des Konfidenzintervalles




## Konfidenzintervall für den Erwartungswert

Wir wollen eine Intervallschätzung für den Erwartungswert ( $\mu$ ) einer Zufallsgröße (zB: Körperhöhe) geben.

Gedankenexperiment:

Nehmen wir jetzt viele Stichproben, (zB: viele Studentengruppen) alle mit gleichem Stichprobenumfang  $n$ .

$\bar{x}_i$  ist der Durchschnitt der  $i$ -ten Stichprobe



11

## Konfidenzintervall für den Erwartungswert




Wie sieht die Verteilung von  $\bar{x}_i$  Werte aus?

Zentraler Grenzwertsatz: bei genug hohen  $n$  die Verteilung der Durchschnittswerte ( $\bar{x}_i$ ) ist eine Normalverteilung.

Lage ( $\mu_{\bar{x}}$ ) und Breite ( $\sigma_{\bar{x}}$ ) der Verteilung der Durchschnittswerte ( $\bar{x}_i$ )?

12


## Daten und ihre Durchschnittswerte



## Verteilung von Durchschnitt der Zufallsgrößen


$x_1$  und  $x_2$  sind unabhängige Zufallsgrößen. (z.B.: Ergebnisse von zwei Körperhöhemessungen) Beide folgen eine Normalverteilung mit derselben Erwartungswerte  $\mu$  und Streuungen  $\sigma$ .

Verallgemeinert:




14

## Konfidenzintervall für den Erwartungswert




15

## Konfidenzintervall für den Erwartungswert



16

## Konfidenzintervall für den Erwartungswert



$\bar{x}_i$  liegt mit 5% Wahrscheinlichkeit im Intervall  $\mu - 2s_{\bar{x}}$   $\mu + 2s_{\bar{x}}$  nicht!

$\mu$  liegt mit 5% Wahrscheinlichkeit im Intervall  $\bar{x} - 2s_{\bar{x}}$   $\bar{x} + 2s_{\bar{x}}$  nicht!

$$\bar{x}_i \leq \mu - 2s_{\bar{x}} \text{ oder } \mu + 2s_{\bar{x}} \leq \bar{x}_i \implies \mu \leq \bar{x}_i - 2s_{\bar{x}} \text{ oder } \bar{x}_i + 2s_{\bar{x}} \leq \mu$$

5% Wahrsch. 5% Wahrsch.

17

## Konfidenzintervall für den Erwartungswert

Der Erwartungswert ( $\mu$ ) liegt in dem Intervall  $\bar{x} - 2s_{\bar{x}}$ ,  $\bar{x} + 2s_{\bar{x}}$  (Konfidenzintervall) mit 95% Wahrscheinlichkeit

Eine ähnliche Ableitung gibt:  $\mu$  liegt


- mit 68% Wahrscheinlichkeit im Intervall:  $\bar{x} - s_{\bar{x}}$ ,  $\bar{x} + s_{\bar{x}}$

- mit 99,7% Wahrscheinlichkeit im Intervall:  $\bar{x} - 3s_{\bar{x}}$ ,  $\bar{x} + 3s_{\bar{x}}$

**Je größer ist die Sicherheitswahrscheinlichkeit desto breiter ist das Konfidenzintervall!**

Bemerkung: wenn  $n \rightarrow \infty$  dann  $s_{\bar{x}} \rightarrow 0$

18



19

## Bestimmung des Stichprobenumfanges

Welcher Stichprobenumfang ist notwendig zu einer bestimmten Genauigkeit? (z.B.: Körperhöhe mit  $\pm 1$  cm „Genauigkeit“ bei 95% Konfidenzniveau)

$$2s_{\bar{x}} = 1 \text{ cm} \implies s_{\bar{x}} = 0,5 \text{ cm}$$

$$s_{\bar{x}} = \frac{s}{\sqrt{n}} \implies s_{\bar{x}}^2 = \frac{s^2}{n} \implies n = \frac{s^2}{s_{\bar{x}}^2}$$

$s = ?$   $s$  kann aus einer kleineren Stichprobe geschätzt werden.

Z.B.: Körperhöhe in einer Studentengruppe (20 St.):  $s = 8,3$  cm

$$n = \frac{s^2}{s_{\bar{x}}^2} = \frac{8.3^2 \text{ cm}^2}{0.5^2 \text{ cm}^2} \approx 276$$

## Konfidenzintervall für Quotient (Wahrscheinlichkeit)

Zwei Möglichkeiten: (E/E, z.B.: **Raucher/Nichtraucher**)

Binomialverteilung

E kommt mit einer Wahrscheinlichkeit von **p** vor.

Stichprobenumfang: **n**

In einem Versuch E kommt **k** –mal vor (**k** aus **n** Personen sind **Raucher**)

Die relative Häufigkeit **h=k/n** ist ein Schätzwert für **p** (Punktschätzung.)

**k** folgt eine Binomialverteilung mit einem Erwartungswert von **pn**

Theoretische Streuung der Binomialverteilung:  $\sigma_k = \sqrt{np(1-p)}$  (Streuung von **k**)

**p** wird mit der relativen Häufigkeit geschätzt:  $\sigma_k \approx \sqrt{nh(1-h)}$

Weil  $p \approx h = k/n$ , Streuung von **p**:  $\sigma = \sigma_k/n = \sqrt{nh(1-h)/n} = \sqrt{h(1-h)/n}$

Analog zu  $\bar{x} \pm 2\sigma$

**p** befindet sich mit 95 % Wahrscheinlichkeit in:

$$h \pm 2\sqrt{h(1-h)/n} \quad (95\% \text{ Konfidenzniveau})$$

z.B.: 20 Raucher aus 100  $\Rightarrow P(\text{Rauchen}) = 0,2 \pm 2\sqrt{0,2 \cdot 0,8/100} = 0,2 \pm 0,08 = (20 \pm 8)\%$

## Zusammenfassung der Schätzungen

Punktsätzungen:

Stich- probe	Grund- gesamtheit
$\bar{x}$	$\mu$
$s$	$\sigma$
$n$	$\infty$
$h$	$P$

Intervallschätzung mit 95%  
Konfidenzniveau

für den Erwartungswert ( $\mu$ ):

$$\bar{x} \pm 2s_{\bar{x}}$$

für die Wahrscheinlichkeit (P):

$$h \pm 2\sqrt{h(1-h)/n}$$

22

