

Grundlagen der Biostatistik und Informatik

Statistische Schätzungen,
Konfidenz, Signifikanz

dr. László Smeller

1

Analytische Statistik



Population

$N = \text{„unendlich“}$

Theoretische Verteilung
Erwartungswert
Theoretische Streuung



Stichprobe

$n = \text{endlich}$

Häufigkeitsverteilung
Durchschnitt
Standardabweichung



2

Repräsentativität der Stichprobe

Quotenstichprobe

Die gleiche Verteilung für wichtige (bekannte) Variablen in der Stichprobe wie in der Grundgesamtheit (z. B. Alter, Geschlecht, ...)

Problem:

Sozio-demographische und psychologische, usw. Merkmale sind oft nicht bekannt (Verteilung und Relevanz).

Zufallsstichprobe

Zufällig ausgewählte Elemente der Grundgesamtheit

Problem mit der Repräsentativität, z.B.: 50:50 Männer und Frauen kommt mit 8% Wahrscheinlichkeit vor. (siehe Binomiale Verteilung)

3

Aufgabe der Schätztheorie

Aus einer Stichprobe Schätzwerte für

- **Wahrscheinlichkeit**
- **Erwartungswert**
- **Streuung**
- oder andere Parametern einer Verteilung zu ermitteln.


Typen der Schätzungen:

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

4

Punktschätzungen

Wir wollen jetzt die Parameter einer Verteilung (μ, σ) 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	$n \uparrow$ bessere Schätzung
Effizienz (wirksam)	kleine Streuung
Exhaustivität (erschöpfend)	berücksichtigt alle Informationen

5


Punktschätzungen

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

Relative Häufigkeit

ist ein Schätzwert für die **Wahrscheinlichkeit**

Siehe Definition der statistischen Wahrscheinlichkeit!




6

Punktschätzungen


Durchschnitt

ist ein Schätzwert für den **Erwartungswert**



Standardabweichung

ist ein Schätzwert für die **Streuung**



Punktschätzungen sagen

nichts über die Genauigkeit bzw. Sicherheit der Schätzung!

7

Intervallschätzungen

Intervallschätzung oder Konfidenzschätzung* gibt zu einer vorgewählten Sicherheitswahrscheinlichkeit γ , (Konfidenzniveau) ein Intervall (c_1, c_2) an, in dem der unbekannte Parameter (zB. μ oder σ) mit einer Wahrscheinlichkeit von mindestens γ liegt.



Zb.: Erwartungswert der Pulszahl ist bei 95% Konfidenzniveau: $74 \pm 6 \frac{1}{\text{Min}}$

*Konfidenz (Latein): Vertraulichkeit

8

Intervallschätzungen

Wie großes γ (Konfidenzniveau) soll gewählt werden?
 Wie groß sind die Schaden bei einer falschen Schätzung?

Sozialwissenschaft $\gamma=0,9$



Medizin $\gamma=0,95$

Technik $\gamma=0,99$



Einfluss der Streuung und des Stichprobenumtanges
 $\alpha=1-\gamma$ Irrtumswahrscheinlichkeit (Signifikanzniveau)

Konfidenzintervall für den Erwartungswert bei bekannter Streuung

1. Nehmen wir an, dass die Varianz (und damit die theoretische Streuung) bekannt ist.

Gedankenversuch:

Sei x eine Zufallsgröße (zB: Pulszahl) mit einer beliebigen Verteilung mit einem Erwartungswert μ und einer Streuung σ .


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

Sei \bar{x}_i der Durchschnitt der i -ten Stichprobe
 Wie sieht die Verteilung von \bar{x}_i Werten aus?

Zentraler Grenzwertsatz: bei genügend hohem n ist die Verteilung eine Normalverteilung.

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

Zur Erinnerung:





Daten und ihre Durchschnittswerte

die Daten streuen um den Durchschnittswert

Pulsfrequenzen (1/Min)

die Durchschnittswerte streuen um den Erwartungswert

Konfidenzintervall für den Erwartungswert



Verteilung von Durchschnitt der Zufallsgrößen

Sei x_1 und x_2 sind unabhängige Zufallsgrößen. Beide folgen einer Normalverteilung mit derselben Erwartungswerten μ und Streuungen σ .


Welche Verteilung folgt der Durchschnitt $\bar{x} = (x_1 + x_2)/2$?

Normalverteilung, mit den folgenden Parametern:

Messwerte	Summe	Durchschnitt	Allgemein für n Messwerte
x_1, x_2	x_1+x_2	$\bar{x} = (x_1 + x_2)/2$	$\bar{x} = (x_1 + \dots + x_n)/n$
μ	$\mu + \mu = 2\mu$	μ	μ
σ^2	$\sigma^2 + \sigma^2 = 2\sigma^2$		
σ	$\sqrt{2} \sigma$	$\sigma/\sqrt{2}$	σ/\sqrt{n}


13

Konfidenzintervall für den Erwartungswert



14

Konfidenzintervall für den Erwartungswert




\bar{x}_i liegt mit 95% Wahrscheinlichkeit im Intervall $\mu - 2\sigma_{\bar{x}} \quad \mu + 2\sigma_{\bar{x}}$

wenn $\mu - 2\sigma_{\bar{x}} \leq \bar{x}_i \leq \mu + 2\sigma_{\bar{x}}$ dann $\bar{x}_i - 2\sigma_{\bar{x}} \leq \mu \leq \bar{x}_i + 2\sigma_{\bar{x}}$
 95% Wahrsch. 95% Wahrsch.

15

Konfidenzintervall für den Erwartungswert



\bar{x}_i liegt mit 95% Wahrscheinlichkeit im Intervall $\mu - 2\sigma_{\bar{x}} \quad \mu + 2\sigma_{\bar{x}}$

d.h.
 $\mu + 2\frac{\sigma}{\sqrt{n}} \quad \mu - 2\frac{\sigma}{\sqrt{n}}$

$\bar{x}_i \leq \mu - 2\sigma_{\bar{x}}$ oder $\mu + 2\sigma_{\bar{x}} \leq \bar{x}_i \iff \mu \leq \bar{x}_i - 2\sigma_{\bar{x}}$ oder $\bar{x}_i + 2\sigma_{\bar{x}} \leq \mu$
 5% Wahrsch. 5% Wahrsch.

16

Konfidenzintervall für den Erwartungswert

Wenn die theoretische Streuung bekannt ist, dann kann das Intervall (Konfidenzintervall) $\bar{x} - 2\sigma_{\bar{x}}$, $\bar{x} + 2\sigma_{\bar{x}}$ angegeben werden, in dem der Erwartungswert (μ) mit 95% Wahrscheinlichkeit liegt.

Eine ähnliche Herleitung gibt: μ ist
- mit 68% Wahrscheinlichkeit im Intervall: $\bar{x} - \sigma_{\bar{x}}$, $\bar{x} + \sigma_{\bar{x}}$

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

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

17

Konfidenzintervall für den Erwartungswert

zB: Eine Maschine herstellt Tabletten, je mit einem vorgeschriebenen Wirkstoffgehalt von 20 mg. Der Wirkstoffgehalt von 10 Tabletten wurde gemessen. Der Durchschnitt beträgt 18,9 mg. Aus einer früheren Messung ist es bekannt, dass die Streuung des Wirkstoffgehalts 1,6 mg ist. Geben Sie das zur 95% Sicherheitswahrscheinlichkeit gehörende Konfidenzintervall an! (17,9 mg 19,9 mg)
Ist diese Maschine gut eingestellt?

Mit einer sehr langen Mess-Serie haben wir der Erwartungswert und die theoretische Streuung der Blutzuckerkonzentration bestimmt. Jetzt wird die Blutzuckerkonzentration in 40 Studentengruppen bestimmt. Wir bestimmen das 95% Konfidenzintervall für jede Gruppe. Wieviele Konfidenzintervalle enthalten den Erwartungswert?

18

Konfidenzintervall für den Erwartungswert bei unbekannter Streuung

2. Am häufigsten ist $\sigma_{\bar{x}}$ nicht bekannt.

Wie kann man das Konfidenzintervall berechnen?

Weil die Standardabweichung eine Punktschätzung der Streuung ist:

$$\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}} \approx \frac{s}{\sqrt{n}} = s_{\bar{x}} \leftarrow \text{Standardfehler}$$

μ liegt mit 95% Wahrscheinlichkeit im $\bar{x} - 2s_{\bar{x}}$, $\bar{x} + 2s_{\bar{x}}$ Bereich.

$\bar{x} \pm 2s_{\bar{x}}$ ist als das zu 95% Konfidenzniveau (Wahrsch.) gehörende Konfidenzintervall genannt.

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


19

Konfidenzintervall für den Erwartungswert

Liegt μ tatsächlich mit 95% Wahrsch. im $\bar{x}_i - 2s_{\bar{x}}$, $\bar{x}_i + 2s_{\bar{x}}$ Bereich?

Die Ungenauigkeit erhöht sich mit der Schätzung der Streuung.

Die Schätzung ist besonders grob, wenn der Stichprobenumfang (n) klein ist.
 \Rightarrow Das Konfidenzintervall muss vergrößert werden!




20

Konfidenzintervall für den Erwartungswert

Bei bekanntem σ folgt


$$\frac{\bar{x} - \mu}{\sigma_{\bar{x}}} = \frac{\bar{x} - \mu}{\sigma} \sqrt{n}$$

eine Standard-Normalverteilung:





Bei unbekanntem σ aber bekanntem s

folgt $\frac{\bar{x} - \mu}{s} \sqrt{n}$ eine t -Verteilung:



Konfidenzintervall für den Erwartungswert



Zu 95% W.:

$$-2 < \frac{\bar{x} - \mu}{\sigma_{\bar{x}}} < 2$$

$$\Leftrightarrow -2 < \frac{\bar{x} - \mu}{\sigma} \sqrt{n} < 2$$

$$\Leftrightarrow \mu < \bar{x} + 2\sigma_{\bar{x}} \quad \mu > \bar{x} - 2\sigma_{\bar{x}}$$

$$\Leftrightarrow \bar{x} + 2\sigma_{\bar{x}} < \mu < \bar{x} - 2\sigma_{\bar{x}}$$



$$-t_{5\%} < \frac{\bar{x} - \mu}{s} \sqrt{n} < t_{5\%}$$

$$\Leftrightarrow -t_{5\%} < \frac{\bar{x} - \mu}{s} \sqrt{n} < t_{5\%}$$

$$\Leftrightarrow \mu < \bar{x} + t_{5\%} \sigma_{\bar{x}} \quad \mu > \bar{x} - t_{5\%} \sigma_{\bar{x}}$$

$$\Leftrightarrow \bar{x} + t_{5\%} \sigma_{\bar{x}} < \mu < \bar{x} - t_{5\%} \sigma_{\bar{x}}$$

Konfidenzintervall für den Erwartungswert



Statt Normalverteilung, haben wir eine t -Verteilung.

Statt „2“ müssen wir die t -Werte der t -Verteilung anwenden.

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


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

Konfidenzintervall für den Erwartungswert

Die t -Tabelle:

Freiheitsgrad	Signifikanzniveau (1- γ)		
	0.05	0.02	0.01
2	4.30266	6.96455	9.92499
3	3.18245	4.54071	5.84085
4	2.77645	3.74694	4.60408
5	2.57058	3.36493	4.03212
6	2.44691	3.14267	3.70743
7	2.36462	2.99795	3.49948
8	2.30601	2.89647	3.35538
9	2.26216	2.82143	3.24984
10	2.22814	2.76377	3.16926
11	2.20099	2.71808	3.10582
12	2.17881	2.68099	3.05454
13	2.16037	2.65030	3.01228
14	2.14479	2.62449	2.97685
15	2.13145	2.60248	2.94673
20	2.08596	2.52798	2.84534
50	2.00856	2.40327	2.67779
70	1.99444	2.38080	2.64790
100	1.98397	2.36421	2.62589
unendlich	1.95996	2.32635	2.57583

$n-1$



μ liegt in $\bar{x} \pm t_{5\%} s_{\bar{x}}$ mit 95% Wahrscheinlichkeit

Konfidenzintervall für den Erwartungswert

Mit Excel:


TINV(Wahrscheinlichkeit;Freiheitsgrad)

$1-\gamma$

$n-1$

z.B.:

TINV(0,05,8)=2,30601≈2,3




μ liegt in $\bar{x} \pm t_{5\%} s_{\bar{x}}$ mit 95% Wahrscheinlichkeit

z.B. $\bar{x}=74 \text{ 1/Min}$, $s=18 \text{ 1/Min}$, $n=9$

$s_{\bar{x}} = 18/\sqrt{9} = 6 \text{ 1/Min}$ $t_{5\%} = 2,3 \Rightarrow 74 \pm 14 \text{ 1/Min}$ 95% W.

Bedeutung der Konfidenz



38 der 40 Konfidenzintervalle (etwa 95%) überdecken den Wert μ_0

2 Konfidenzintervalle (etwa 5%) dagegen nicht

Pr.Buch Abb. 11

26

Zusammenfassung der Schätzungen

Punktschätzungen:

Stichprobe	Grundgesamtheit
\bar{x}	μ
s	σ
n	∞

Intervallschätzungen

1. σ ist bekannt:

$$\mu \pm 2 \frac{\sigma}{\sqrt{n}} \quad 95\%$$

2. σ ist unbekannt:

Grob:

$$\bar{x} \pm 2s_{\bar{x}} \quad 95\%$$

Genau:

$$\bar{x} \pm t_{5\%} s_{\bar{x}} \quad 95\%$$

27

Bestimmung des Stichprobenumfanges

Welcher Stichprobenumfang ist notwendig zu einer bestimmten Genauigkeit?

(z.B.: Körperhöhe mit $\pm 1\text{cm}$ „Genauigkeit“ bei 95% Konfidenzniveau)

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

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

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

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

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

28

Konfidenzintervall für Quotienten

Zwei Möglichkeiten: (E/ \bar{E} , z.B.: Raucher/Nichtraucher)

Binomialverteilung

E kommt mit Wahrscheinlichkeit p vor.

Stichprobenumfang: n

p wird aus der relativen Häufigkeit geschätzt: $p = n_E/n$

Streuung der Binomialverteilung: $\sigma = \sqrt{np(1-p)}$

Analog zu $\bar{x} \pm 2\sigma/\sqrt{n}$

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

z.B.: 20 Raucher aus 100 $\rightarrow 0,2 \pm 2\sqrt{0,2 \cdot 0,8/100} = 0,2 \pm 0,08$