

Anmerkungen zur Vorlesung Statistik vom 20.12.2016

Inhalt:

- Intervall-Schätzung
 - Umsetzung mit R
- Signifikanztests
 - Grundlagen
 - Einstichproben-Gaußtest, Einstichproben-t-Test, approximativer Gaußtest
 - Chi-Quadrat Test für die Varianz
 - Kontingenztest

Aufgabensammlung Statistik:

Aufgabe 83: Tests Fehler 1. Art	91
Aufgabe 84: Tests Erwartungswert	92
Aufgabe 85: Tests Erwartungswert	93
Aufgabe 86: Intervallschätzer	94
Aufgabe 87: Intervallschätzer	95
Aufgabe 88: Intervallschätzer Tests	96
Aufgabe 89: Intervallschätzer	97
Aufgabe 90: Konfidenzintervall Anteil	98
Aufgabe 91: Tests Anteil	99
Aufgabe 92: Tests Fehler	100
Aufgabe 93: Tests Kontingenz	101
Aufgabe 94: Tests Kontingenz	102
Aufgabe 95: Tests Kontingenz	103
Aufgabe 96: Tests Kontingenz	104

20.12.2016
 Hausaufgabe
 A83-A85,
 A87-A88 fertig
 sowie
 A91-A96

Klausurtermin: Freitag, 13. Januar 2017, 15:30 Uhr

13.1	15:30	IN3_2012	95	Statistik	Wins/Etschberger	90	M1.01	AW
13.1	15:30	IN3_2007	2	Statistik	Wins/Etschberger	90	M1.02	AW
13.1	15:30	WI2_2014	60	Statistik	Etschberger/Wins	90	J2.18	AW
13.1	15:30	WI2_2012	8	Statistik	Etschberger/Wins	90	J3.19	AW
13.1	15:30	WI2_2007	2	Statistik	Etschberger/Wins	90	W3.03	AW
13.1	15:30						Res.:	Wins/Etschberge

WDH-/Fragestunde: Dienstag, 10. Januar 2017, 14:00 – 17:00 Uhr, Raum W3.02
 Fragen bitte vorab an anett.wins@wiwi.uni-augsburg.de



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests

Quellen
Tabellen

Beispiel:

$$G \sim N(\mu; \sigma);$$

$$(x_1, \dots, x_5) = (1, 1.5, 2.5, 3, 2)$$

Gesucht: KI für σ^2 zum Konfidenzniveau $1 - \alpha = 0,99$

1 $1 - \alpha = 0,99$

2 $\chi^2(5 - 1) : c_1 = x_{\frac{\alpha}{2}} = x_{0,005} = 0,21$
 $c_2 = x_{1 - \frac{\alpha}{2}} = x_{0,995} = 14,86$ } Folie 219 χ^2 -Vert.

3 $\bar{x} = \frac{1}{5} (1 + 1,5 + 2,5 + 3 + 2) = 2$
 $\sum_{i=1}^5 x_i^2 - 5 \cdot \bar{x}^2 = 1^2 + 1,5^2 + 2,5^2 + 3^2 + 2^2 - 5 \cdot 2^2 = 2,5$ } TR möglich!

4 KI = $\left[\frac{2,5}{14,86}; \frac{2,5}{0,21} \right] = [0,17; 11,9]$

(Extrem groß, da n klein.)

Signifikanztests



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests

Quellen
Tabellen

- ▶ Vorliegen einer **Hypothese** über die Verteilung(en) der Grundgesamtheit(en).
- ▶ Beispiele:
 - „Der Würfel ist fair.“
 - „Die Brenndauern zweier unterschiedlicher Glühbirnensorten sind gleich.“
- ▶ Hypothese soll anhand einer Stichprobe überprüft werden.
- ▶ Prinzip:
 - **Hypothese verwerfen**, wenn „signifikanter“ Widerspruch zur Stichprobe.
 - Ansonsten: **Hypothese nicht verwerfen**.
- ▶ Eine verworfene Hypothese gilt als statistisch widerlegt.
- ▶ Nicht-Verwerfung ist dagegen ein „Freispruch aus Mangel an Beweisen“.

Zu Beachten:

Nicht-Verwerfung ist **kein** „statistischer Beweis“, dass Hypothese wahr ist!
 („Trick“: Hypothese falsch \iff Gegenhypothese wahr!)

Test des Erwartungswertes bei bekannter Varianz in der Grundgesamtheit



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
- Quellen
- Tabellen

► Zunächst:

- $G \sim N(\mu; \sigma)$ mit σ bekannt
- Einfache Stichprobe X_1, \dots, X_n
- (Null-)Hypothese $H_0 : \mu = \mu_0$

► **Beispiel:**

X_1, \dots, X_{25} mit $X_i =$ Füllmenge der i -ten Flasche $\sim N(\mu; 1,5)$

Nullhypothese $H_0 : \mu = 500$, d.h. $\mu_0 = 500$

► Je nach Interessenlage sind unterschiedliche **Gegenhypothesen** möglich:

- a) $H_1 : \mu \neq \mu_0$
- b) $H_1 : \mu < \mu_0$
- c) $H_1 : \mu > \mu_0$

► Entscheidung:

- $H_0 : \mu = \mu_0$ wird abgelehnt gegenüber
- a) $H_1 : \mu \neq \mu_0$, wenn $|\bar{x} - \mu_0|$ „sehr groß“ ist
 - b) $H_1 : \mu < \mu_0$, wenn \bar{x} „weit kleiner“ als μ_0 ist
 - c) $H_1 : \mu > \mu_0$, wenn \bar{x} „weit größer“ als μ_0 ist

Test des Erwartungswertes bei bekannter Varianz in der Grundgesamtheit



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
- Quellen
- Tabellen

Entscheidungskriterium aus Stichprobe:

$$v = \frac{\bar{x} - \mu_0}{\sigma} \sqrt{n}$$

► Vorteil: Verteilung bekannt: $N(0; 1)$

Handwritten: $\checkmark \overset{H_0}{\sim} N(0,1)$



► Dann:

$H_0 : \mu = \mu_0$ wird abgelehnt gegenüber

- a) $H_1 : \mu \neq \mu_0$, wenn $|v|$ „sehr groß“ ist
- b) $H_1 : \mu < \mu_0$, wenn v „sehr negativ“ ist
- c) $H_1 : \mu > \mu_0$, wenn v „sehr positiv“ ist

Mögliche Fehlentscheidungen

- Ablehnung von H_0 , obwohl H_0 richtig ist: **Fehler 1. Art**
- Nicht-Ablehnung von H_0 , obwohl H_0 falsch ist: **Fehler 2. Art**



► **Signifikanzniveau α :** Maximal erlaubte Wahrscheinlichkeit für einen Fehler 1. Art.

Test des Erwartungswertes bei bekannter Varianz in der Grundgesamtheit

Statistik



- ▶ Mithilfe von α und V kann geklärt werden, was „sehr groß“ usw. heißt:

Wahrscheinlichkeit für Fehler 1. Art im Fall

a): $|v| > x$, obwohl H_0 richtig:

$$\begin{aligned} P(|V| > x) &= P(V > x) + P(V < -x) \\ &= 2 \cdot P(V > x) \quad (\text{Symmetrie der Normalverteilung}) \end{aligned}$$

$$= 2 \cdot [1 - P(V \leq x)] = 2 \cdot [1 - \Phi(x)] \stackrel{!}{=} \alpha$$

$$\Leftrightarrow \Phi(x) = 1 - \frac{\alpha}{2}$$

$$\Leftrightarrow x = x_{1-\frac{\alpha}{2}}$$

H_0 wird demnach verworfen, wenn $|v| > x_{1-\frac{\alpha}{2}}$ bzw. $v \in B$ ist.

$B = (-\infty; -x_{1-\frac{\alpha}{2}}) \cup (x_{1-\frac{\alpha}{2}}; \infty)$ heißt **Verwerfungsbereich**.


- ▶ Analoge Vorgehensweise für die Fälle b) und c)

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
- Quellen
- Tabellen

192

Test des Erwartungswertes bei bekannter Varianz in der GG

Statistik



Rezept

- 1 Ein Signifikanzniveau α wird festgelegt.
- 2 Der Verwerfungsbereich

$$B = (-\infty; -x_{1-\alpha/2}) \cup (x_{1-\alpha/2}; \infty) \quad \text{im Fall a)}$$

$$B = (-\infty; -x_{1-\alpha}) \quad \text{im Fall b)}$$

$$B = (x_{1-\alpha}; \infty) \quad \text{im Fall c)}$$

wird festgelegt, wobei $x_{1-\alpha/2}$ bzw. $x_{1-\alpha}$ das $(1 - \alpha/2)$ - bzw. das $(1 - \alpha)$ -Fraktile der $N(0,1)$ -Verteilung ist. (**Wichtig**: Der Ablehnungsbereich ist also unabhängig von der Stichprobe)

- 3 **Wichtig**: Erst jetzt werden die Daten der Stichprobe erhoben/beachtet:

Der Testfunktionswert $v = \frac{\bar{x} - \mu_0}{\sigma} \sqrt{n}$ wird berechnet.

- 4 H_0 wird genau dann verworfen, wenn $v \in B$ gilt.

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
- Quellen
- Tabellen

193



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
- Quellen
- Tabellen


Beispiel:

X_1, \dots, X_{25} mit $X_i \sim N(\mu; 1,5)$ und $\bar{x} = 499,28$

Prüfe $H_0 : \mu = 500$, $H_1 : \mu \neq 500$ zum Signifikanzniveau $\alpha = 0,01$

Lösung: Einstichproben-Gaußtest, Fall a)

- 1 $\alpha = 0,01$
- 2 $N(0; 1) : x_{1-\frac{\alpha}{2}} = x_{1-0,005} = x_{0,995} = 2,576$
 $\Rightarrow B = (-\infty; -2,576) \cup (2,576; \infty)$
- 3 $v = \frac{499,28-500}{1,5} \cdot \sqrt{25} = -2,4$
- 4 $v \notin B \Rightarrow H_0$ nicht verwerfen



Interpretation: Zum Signifikanzniveau 1 % kann der Brauerei keine Abweichung vom Sollwert $\mu_0 = 500$ nachgewiesen werden.

Einstichproben-t-Test und approximativer Gaußtest



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
- Quellen
- Tabellen

Gegeben:

- ▶ Einfache Stichprobe X_1, \dots, X_n mit
- ▶ $E(X_i) = \mu$, $\text{Var}(X_i) = \sigma^2$

Hypothesenpaare:

- a) $H_0 : \mu = \mu_0$ $H_1 : \mu \neq \mu_0$
- b) $H_0 : \mu = \mu_0$ (oder $\mu \geq \mu_0$), $H_1 : \mu < \mu_0$
- c) $H_0 : \mu = \mu_0$ (oder $\mu \leq \mu_0$), $H_1 : \mu > \mu_0$

Voraussetzungen:

- 1 Normalverteilung mit σ unbekannt (**Einstichproben-t-Test**)
oder
- 2 Beliebige Verteilung
mit $n > 30$ bzw. $5 \leq \sum x_i \leq n - 5$ (bei $B(1; p)$)
(**approximativer Gaußtest**) *dichotom / 0-1-kodiert ...*



Ablauf:

- 1 Festlegen des **Signifikanzniveaus** α
- 2 Festlegen des **Verwerfungsbereichs** B:
 - Falls $H_1 : \mu \neq \mu_0$: $B = (-\infty; -x_{1-\alpha/2}) \cup (x_{1-\alpha/2}; \infty)$
 - Falls $H_1 : \mu < \mu_0$: $B = (-\infty; -x_{1-\alpha})$
 - Falls $H_1 : \mu > \mu_0$: $B = (x_{1-\alpha}; \infty)$

Dabei steht $x_{1-\alpha/2}$ bzw. $x_{1-\alpha}$ für das jeweilige Fraktil

- der $t(n-1)$ -Verteilung bei $n \leq 29$ bzw.
- der $N(0; 1)$ -Verteilung bei $n \geq 30$.


- 3 Berechnen des **Testfunktionswertes**:

$$v = \begin{cases} \frac{\bar{x} - \mu_0}{s} \sqrt{n} & \text{falls Grundgesamtheit } N(\mu; \sigma)\text{-verteilt, } \sigma \text{ unbekannt} \\ & \text{oder falls Verteilung der } G\phi \text{ beliebig, } n > 30, \sigma \text{ unbekannt} \\ \frac{\bar{x} - \mu_0}{\sigma} \sqrt{n} & \text{falls Verteilung der } G\phi \text{ beliebig, } n > 30, \sigma \text{ bekannt} \\ \frac{\bar{x} - \mu_0}{\sqrt{\mu_0(1-\mu_0)}} \sqrt{n} & \text{falls } G\phi \text{ gemäß } B(1; \mu)\text{-verteilt, } \mu \rightarrow 0,5 \leq \sum x_i \leq n-0,5 \end{cases}$$

dichotom

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
- Quellen
- Tabellen

Einstichproben-t-Test: Beispiel




Beispiel t-Test: Energieaufnahme von Frauen

- ▶ Empfohlene täglich Energieaufnahme für Frauen: 7724 kJ (1845 kcal)
- ▶ Nehme einfache Stichprobe von 11 Frauen und teste zum Signifikanzniveau $\alpha = 0,05$ für
- ▶ H_0 : „Der Erwartungswert der täglichen Energieaufnahme für Frauen ist 7724 kJ“ (μ_0)
- ▶ gegen $H_1: \mu \neq \mu_0$

```
daily.intake <- c(5260, 5470, 5640, 6180, 6390, 6515, 6805, 7515, 7515, 8230, 8770)
t.test(daily.intake, alternative="two.sided", mu=7724, conf.level=0.95)
```

```
##
## One Sample t-test
##
## data: daily.intake
## t = -2.8179, df = 10, p-value = 0.01823
## alternative hypothesis: true mean is not equal to 7724
## 95 percent confidence interval:
## 5986.348 7520.925
## sample estimates:
## mean of x
## 6753.636
```



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
- Quellen
- Tabellen

\Rightarrow Testentscheidung: $p < \alpha \Rightarrow H_0$ ablehnen (signifik. Testergebnis)

Beispiel: Einstichproben-t-Test

vgl. S 194

$$s = 1,6$$

$$\textcircled{1} \alpha = 0,01$$

$$\textcircled{2} t(25-1) = t(24) : x_{0,995} = 2,797$$
$$\Rightarrow B = (-\infty; 2,797) \cup (2,797; \infty)$$

$$\textcircled{3} v = \frac{499,28 - 500}{1,6} \cdot \sqrt{25} = -2,25$$

$\textcircled{4} v \notin B \Rightarrow H_0$ nicht verwerfen.

Einstichproben-t-Test: Beispiel

Statistik



Beispiel t-Test: Energieaufnahme von Frauen

- ▶ Empfohlene täglich Energieaufnahme für Frauen: 7724 kJ (1845 kcal)
- ▶ Nehme einfache Stichprobe von 11 Frauen und teste zum Signifikanzniveau $\alpha = 0,05$ für
- ▶ H_0 : „Der Erwartungswert der täglichen Energieaufnahme für Frauen ist 7724 kJ“ (μ_0)
- ▶ gegen $H_1: \mu \neq \mu_0$

```
daily.intake <- c(5260, 5470, 5640, 6180, 6390, 6515, 6805, 7515, 7515, 8230, 8770)
t.test(daily.intake, alternative="two.sided", mu=7724, conf.level=0.95)


##
## One Sample t-test
##
## data:  daily.intake
## t = -2.8179, df = 10, p-value = 0.01823
## alternative hypothesis: true mean is not equal to 7724
## 95 percent confidence interval:
##  5986.348 7520.925
## sample estimates:
## mean of x
##  6753.636
```

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
- Quellen
- Tabellen

199

Einstichproben-t-Test, approx. Gaußtest

Statistik



Beispiel:

$X_1, \dots, X_{2000} \sim B(1; p)$ mit

$$X_i = \begin{cases} 1, & \text{falls } i\text{-te Person Wähler einer bestimmten Partei} \\ 0, & \text{sonst} \end{cases}$$

Ergebnis der Stichprobe: $\sum_{i=1}^{2000} x_i = 108$

Prüfe $H_0: p \leq 0,05$ gegen $H_1: p > 0,05$ zum Signifikanzniveau 2%

Lösung:

approximativer Gaußtest bei dichotomer (zweiwertiger) Verteilung; Voraussetzung 2 erfüllt: $5 \leq 108 \leq 2000 - 5$

- 1 $\alpha = 0,02$
- 2 $N(0; 1): x_{1-\alpha} = x_{0,98} = 2,05$ (Tabelle) $\Rightarrow B = (2,05; \infty)$
- 3 $v = \frac{108 - 2000 \cdot 0,05}{\sqrt{0,05 \cdot (1 - 0,05)}} \sqrt{2000} = 0,82$
- 4 $v \notin B \Rightarrow H_0$ nicht verwerfen

Zusatzfrage: Entscheidung, falls $\alpha = 0,01$? \rightarrow Keine Änderung!

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
- Quellen
- Tabellen

200

Chi-Quadrat-Test für die Varianz

Statistik



- ▶ Gegeben: Einfache Stichprobe $X_1, \dots, X_n \sim N(\mu; \sigma)$
- ▶ Hypothesenpaare:

$$\begin{aligned} \text{a) } H_0 : \sigma^2 &= \sigma_0^2 & H_1 : \sigma^2 &\neq \sigma_0^2 \\ \text{b) } H_0 : \sigma^2 &= \sigma_0^2 \text{ (oder } \sigma^2 \geq \sigma_0^2), & H_1 : \sigma^2 &< \sigma_0^2 \\ \text{c) } H_0 : \sigma^2 &= \sigma_0^2 \text{ (oder } \sigma^2 \leq \sigma_0^2), & H_1 : \sigma^2 &> \sigma_0^2 \end{aligned}$$

▶ Vorgehensweise:

- 1 Festlegen des **Signifikanzniveaus** α .
- 2 Festlegen des **Verwerfungsbereichs**:

$$B = [0; x_{\alpha/2}) \cup (x_{1-\alpha/2}; \infty)$$

$$B = [0; x_\alpha)$$

$$B = (x_{1-\alpha}; \infty)$$

im Fall a)

im Fall b)

im Fall c)

⚠ Fraktiwerte der $\chi^2(n-1)$ -Verteilung = Freiheitsgrade

- 3 Berechnung des **Testfunktionswertes**:

$$v = \frac{(n-1)s^2}{\sigma_0^2} = \frac{1}{\sigma_0^2} \sum_{i=1}^n (x_i - \bar{x})^2$$

⚠ s^2 mit Taschenrechner (TR) berechnen!

201

Chi-Quadrat-Test für die Varianz

Statistik



Beispiel: $G \sim N(\mu; \sigma)$

$(x_1, \dots, x_{10}) = (2100; 2130; 2150; 2170; 2210; 2070; 2230; 2150; 2230; 2200)$

Prüfe $H_0 : \sigma = 40$, $H_1 : \sigma \neq 40$ zum Signifikanzniveau $\alpha = 0,1$

Lösung: χ^2 -Test für die Varianz, Hypothese Fall a);
Voraussetzungen sind erfüllt

- 1 $\alpha = 0,1$
- 2 $\chi^2(9) : x_{\frac{\alpha}{2}} = x_{0,05} = 3,33$; $x_{1-\frac{\alpha}{2}} = x_{0,95} = 16,92$
(Tabelle der χ^2 -Verteilung)

} Folie 219

$$\Rightarrow B = [0; 3,33) \cup (16,92; \infty)$$

- 3 $\bar{x} = \frac{1}{10} (2100 + 2130 + \dots + 2200) = 2164$
 $v = \frac{1}{40^2} [(2100 - 2164)^2 + \dots + (2200 - 2164)^2] = 16,65$
 $\Rightarrow v \notin B \Rightarrow H_0$ nicht verwerfen

oder: $v = \frac{(n-1)s^2}{\sigma_0^2}$ mit TR

9 // 40 //

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
- Quellen
- Tabellen

202

Zwei verbundene einfache Stichproben: Kontingenztest

Statistik



- ▶ Situation: In Grundgesamtheit G: **Zwei verbundene einfache Stichproben**, also Beobachtung **zweier Merkmale X, Y**
- ▶ Hypothese:

H_0 : Die beiden Merkmale X und Y sind in G **unabhängig**.
 H_1 : X und Y sind in G **abhängig**.

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests

Quellen

Tabellen

Vorgehensweise Kontingenztest:

- 1 Festlegen des **Signifikanzniveaus** α .
- 2 Unterteilung der x-Achse in $k \geq 2$ und die y-Achse in $l \geq 2$ disjunkte, aneinander angrenzende Intervalle A_1, \dots, A_k bzw. B_1, \dots, B_l
- 3 Erstellen einer Kontingenztafel mit Randhäufigkeiten:

$x \downarrow y \rightarrow$	B_1	B_2	\dots	B_l	
A_1	h_{11}	h_{12}	\dots	h_{1l}	$h_{1\bullet}$
A_2	h_{21}	h_{22}	\dots	h_{2l}	$h_{2\bullet}$
\vdots	\vdots	\vdots	\vdots	\vdots	
A_k	h_{k1}	h_{k2}	\dots	h_{kl}	$h_{k\bullet}$
	$h_{\bullet 1}$	$h_{\bullet 2}$	\dots	$h_{\bullet l}$	n

203

Zwei verbundene einfache Stichproben: Kontingenztest

Statistik



Vorgehensweise Kontingenztest (Fortsetzung):

- 4 Mit dem Fraktilwert $x_{1-\alpha}$ der χ^2 -Verteilung mit $(k-1) \cdot (l-1)$ Freiheitsgraden: Berechnung des **Verwerfungsbereichs**

$$B = (x_{1-\alpha}; \infty)$$

- 5 Zu jeder Kombination aus $i = 1, \dots, k$ und $j = 1, \dots, l$: Berechnung der Größe

$$\tilde{h}_{ij} = \frac{h_{i\bullet} \cdot h_{\bullet j}}{n}$$

- 6 Berechnung des **Testfunktionswerts** v :

$$v = \sum_{i=1}^k \sum_{j=1}^l \frac{(\tilde{h}_{ij} - h_{ij})^2}{\tilde{h}_{ij}} = \sum_{i=1}^k \sum_{j=1}^l \frac{h_{ij}^2}{\tilde{h}_{ij}} - n$$

- 7 **Ablehnung** von H_0 genau dann, wenn $v \in B$.

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests

Quellen

Tabellen

204

Zwei verbundene einfache Stichproben: Kontingenztest

Statistik



Kontingenztest: Beispiel

- ▶ 400 Erstkandidaten einer praktischen Führerscheinprüfung schneiden abhängig von der besuchten Fahrschule folgendermaßen ab:

	Fahrschule		
	A	B	C
bestanden	130	88	62
durchgefallen	70	38	12

- ▶ Zum Signifikanzniveau von 5 % soll getestet werden, ob das Bestehen der Prüfung unabhängig von der besuchten Fahrschule ist.

- 4 χ^2 -Verteilung mit $(3 - 1) \cdot (2 - 1) = 2$ Freiheitsgraden:
 $\alpha_{1-0,05} = \alpha_{0,95} = 5,99$:

$$B = (5,99; \infty)$$

- 5 Berechnung der \tilde{h}_{ij} :

	A	B	C
best. $\tilde{h}_{11} = 140$	88,2	51,8	
durchg.	60	37,8	22,2

Testdurchführung

- 1 Signifikanzniveau $\alpha = 5\%$
- 2 entfällt, da Skalenniveau nominal
- 3 Kontingenztafel:

	A	B	C	Σ
best. $h_{11} = 130$	88	62	280	
durchg.	70	12	120	
Σ	200	126	74	400

$$\tilde{h}_{11} = \frac{200 \cdot 280}{400} = 140$$

- 6 $v = \frac{(140 - 130)^2}{140} + \dots$
 $+ \frac{(22,2 - 12)^2}{22,2}$
 $\approx 9,077$

- 7 $v \in B$: Also wird H_0 abgelehnt, die Prüfungsergebnisse sind abhängig von der Fahrschule.

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
- Quellen
- Tabellen

205

Quellenübersicht

Statistik



Bücher

- Bamberg, Günter, Franz Baur und Michael Krapp (2011). **Statistik**. 16. Aufl. München: Oldenbourg Verlag. ISBN: 3486702580.
- Dalgaard, Peter (2002). **Introductory Statistics with R**. New York: Springer.
- Fahrmeir, Ludwig, Rita Künstler, Iris Pigeot und Gerhard Tutz (2009). **Statistik: Der Weg zur Datenanalyse**. 7. Aufl. Berlin, Heidelberg: Springer. ISBN: 3642019382.

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
- Quellen
- Tabellen

206




Quellen zu Bildern und Daten

- Anscombe, Francis (1973). „Graphs in Statistical Analysis“. In: *The American Statistician*, S. 195–199.
- Bach, Axel, Reinhard Brüning, Katrin Krief, Hilmar Liebsch und Martin Rosenberg (2006). *Mit Zahlen lügen*. URL: http://www.wdr.de/tv/quarks/sendungsbeitraege/2006/1017/000_zahlen.jsp.
- Fahrmeir, Ludwig, Rita Künstler, Iris Pigeot und Gerhard Tutz (2009). *Statistik: Der Weg zur Datenanalyse*. 7. Aufl. Berlin, Heidelberg: Springer. ISBN: 3642019382.
- Kramer, Walter (2011). *So lügt man mit Statistik*. Piper Verlag. ISBN: 3492264131.

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
- Quellen**
- Tabellen

Binomialverteilung $X \sim B(n; p)$, Verteilungsfunktion $F(x) = P(X \leq x)$



n = 2

↓x p →	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.9801	0.9604	0.9409	0.9216	0.9025	0.8836	0.8649	0.8464	0.8281	0.8100	0.6400	0.5625	0.4900	0.3600	0.2500
1	0.9999	0.9996	0.9991	0.9984	0.9975	0.9964	0.9951	0.9936	0.9919	0.9900	0.9600	0.9375	0.9100	0.8400	0.7500

n = 3

↓x p →	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.9703	0.9412	0.9127	0.8847	0.8574	0.8306	0.8044	0.7787	0.7536	0.7290	0.5120	0.4219	0.3430	0.2160	0.1250
1	0.9997	0.9988	0.9974	0.9953	0.9928	0.9896	0.9860	0.9818	0.9772	0.9720	0.8960	0.8438	0.7840	0.6480	0.5000
2	1.0000	1.0000	1.0000	0.9999	0.9999	0.9998	0.9997	0.9995	0.9993	0.9990	0.9920	0.9844	0.9730	0.9360	0.8750

n = 4

↓x p →	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.9606	0.9224	0.8853	0.8493	0.8145	0.7807	0.7481	0.7164	0.6857	0.6561	0.4096	0.3164	0.2401	0.1296	0.0625
1	0.9994	0.9977	0.9948	0.9909	0.9860	0.9801	0.9733	0.9656	0.9570	0.9477	0.8192	0.7383	0.6517	0.4752	0.3125
2	1.0000	1.0000	0.9999	0.9998	0.9995	0.9992	0.9987	0.9981	0.9973	0.9963	0.9728	0.9492	0.9163	0.8208	0.6875
3	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9984	0.9961	0.9919	0.9744	0.9375

n = 5

↓x p →	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.9510	0.9039	0.8587	0.8154	0.7738	0.7339	0.6957	0.6591	0.6240	0.5905	0.3277	0.2373	0.1681	0.0778	0.0313
1	0.9990	0.9962	0.9915	0.9852	0.9774	0.9681	0.9575	0.9456	0.9326	0.9185	0.7373	0.6328	0.5282	0.3370	0.1875
2	1.0000	0.9999	0.9997	0.9994	0.9988	0.9980	0.9969	0.9955	0.9937	0.9914	0.9421	0.8965	0.8369	0.6826	0.5000
3	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9998	0.9997	0.9995	0.9933	0.9844	0.9692	0.9130	0.8125
4	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9997	0.9990	0.9976	0.9898	0.9688

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
- Quellen**
- Tabellen
- Binomialverteilung
- Poissonverteilung
- Standardnormalverteilung
- χ^2 -Verteilung
- t-Verteilung
- F-Verteilung

Überblick Signifikanztests

$H_0: \mu = \mu_0$
falls Dichtefunktion
entspricht $\mu = \mu_0$

Test auf?

eine einfache STP

$H_0: \sigma^2 = \sigma_0^2$

STP?

...

zwei verbundene einfache STP

Test auf?

$H_0: X, Y$ sind unabhängig

Kontingenztest

$X \sim N(\mu, \sigma)$

Verg.?
 $X \sim B(n, p)$

$X \sim \text{bel.}$
Vor.: $n > 30$

Verg.?

Chi-Quadrat-Test
für die Varianz

$X \sim N(\mu, \sigma)$

σ bekannt
 σ unbekannt

$5 \leq \sum x_i \leq m \cdot 5$
(Voraussetzung
und $n \geq 30$)

σ bekannt
 σ unbekannt



$$\bar{x} = \frac{\sum x_i}{n}$$

Alternativhypothese:

- a) $H_1: \mu \neq \mu_0$
- b) $H_1: \mu < \mu_0$
- c) $H_1: \mu > \mu_0$

Ablehnbereich:

- a) $B = (-\infty; -X_{1-\alpha/2}) \cup (X_{1-\alpha/2}; \infty)$
- b) $B = (-\infty; -X_{1-\alpha})$
- c) $B = (X_{1-\alpha}; \infty)$

$$s^2 = \frac{(n-1)s^2}{\sigma_0^2} = \frac{1}{\sigma_0^2} \sum_{i=1}^n (x_i - \bar{x})^2$$

- a) $H_1: \sigma^2 \neq \sigma_0^2$; $B = [0; X_{\alpha/2}] \cup (X_{1-\alpha/2}; \infty)$
- b) $H_1: \sigma^2 < \sigma_0^2$; $B = [0; X_{\alpha}]$
- c) $H_1: \sigma^2 > \sigma_0^2$; $B = (X_{1-\alpha}; \infty)$

Frakt. aus $\chi^2(n-1)$ - Verteilung.

ganzes Spalte

$$s^2 = \sum_{i=1}^k \sum_{j=1}^n \frac{(h_{ij} - h_{i.}h_{.j})^2}{h_{ij}} = \sum_{i=1}^k \sum_{j=1}^n \frac{h_{ij}^2}{h_{ij}} - n$$

mit $h_{ij} = \frac{n_{i.} \cdot n_{.j}}{n}$ (erwartete Häufigkeiten)

$H_1: X$ und Y sind in G abhängig; $B = (X_{1-\alpha}; \infty)$

Frakt. aus $\chi^2((k-1) \cdot (l-1))$ - Verteilung.

Testentscheidung: H_0 ablehnen falls i) p value $< \alpha$ (Signifikanzniveau)
ii) $\mu_0 \notin KI_{\mu_0}$...
iii) $\mu_0 \notin KI_{\mu_0}$...

```
#####
# 13.12.2016: Konfidenzintervalle
#####

###Konfidenzintervall für  $\mu$  bei unbekannter Varianz
#Datenvektor
x <- c(184.2, 182.6, 185.3, 184.5, 186.2, 183.9, 185.0, 187.1, 184.4)

#Konfidenzintervallbestimmung
t.test(x,conf.level=.99)
#t.test(x, mu=184, conf.level=.99)
t.test(x,conf.level=.95)
t.test(x,conf.level=.90)

#direkter Zugriff auf KI:
t.test(x,conf.level=.99)$conf.int

# -----
# Konfidenzintervall für  $\mu$  bei unbekannter Varianz
setwd("C:/Users/winsanet/Dropbox/HSA/WS2016_17/Daten")
Umfrage<-read.csv2("Umfrage_HSA_2016_10.csv", header=T)
attach(Umfrage)

###Linearisierter QQ-Plot (Normalverteilung)
#qqnorm(Groesse, pch=20)
#qqline(Groesse, col=2, lwd=3, lty=2)

# Konfidenzintervall für  $\mu$  bei unbekannter Varianz
N = 20 # Anzahl Stichproben
n = 5 # Umfang einzelne Stichprobe
conf.level=0.80 # Konfidenzniveau
mu = mean(Groesse)
A.Stichproben = matrix(nrow=N, ncol=n)
set.seed(5)
for(i in 1:N)
  { A.Stichproben[i,] = sample(Groesse, size = n, replace=TRUE) }

A.Stichproben[1,]

A.KI = matrix(nrow=N,ncol=2)
alpha = (1-conf.level)
x.c = qt(p=1-alpha/2, df = n-1)

for (i in 1:N) {
x = A.Stichproben[i,]
s = sd(x)
x.m = mean(x)
A.KI[i,] = x.m + s*x.c*c(-1,1)/sqrt(n)
}

A.KI[20,]

# -----
min=min(A.Stichproben) - (max(A.Stichproben)-min(A.Stichproben))*0.5
max=max(A.Stichproben) + (max(A.Stichproben)-min(A.Stichproben))*0.5
plot(c(min,max), c(1, N), type="n", xlab="", yaxt="n", ylab="")
abline(h=1:N, col="lightgray", lty=2)
KI.falsch = 0
for(i in 1:N) {
```

```

x.data = as.numeric(A.Stichproben[i,])
x.KI = as.numeric(A.KI[i,])
points(jitter(x.data), rep(i, n), pch=16, cex=1, col="#2040dd60")
Farbe = "#dd203060"
if (mu>=A.KI[i,1] & mu<=A.KI[i,2]) {Farbe = "#20dd3060"}
else {KI.falsch = KI.falsch + 1}
points(x.KI, rep(i, 2), pch=15, cex=2, col=Farbe)
lines(x.KI, rep(i, 2), lwd=5, pch=16, cex=2, col=Farbe)
text(min,i,labels = round(x.KI[1],2), cex=0.8, col="darkgreen")
text(max,i,labels = round(x.KI[2],2), cex=0.8, col="darkgreen") }

# Zeichne mu
abline(v=mu, col="#20dd3099", lwd=2, lty=2)
title(sub=paste("Mittelwert Grundgesamtheit = ", round(mu, 2), "; Anzahl
falsch: ", KI.falsch, "; Fehlerquote = ", KI.falsch/N))
# -----

#####
# 20.12.2016: Signifikanztest - Kontingenztest
#####

setwd("C:/Users/winsanet/Dropbox/HSA/WS2016_17/Daten")
Umfrage<-read.csv2("Umfrage_HSA_2016_10.csv", header=T)
attach(Umfrage)

alpha=0.05
n=100
D = na.omit(Umfrage)
set.seed(2)
i = sample.int(length(D[,1]), size = n, replace = T)
# Test, ob Größe der Väter und Note unabhängig (H0)
G = D[i,"GroesseV"]
Groesse = cut(G, breaks=c(min(G), median(G), max(G)), include.lowest = T)
N = D[i,"NoteMathe"]
Note = cut(N, breaks=c(1,2,3,4,5), include.lowest = T)

Tabelle = table(Groesse, Note)
#install.packages("gmodels") #Paket vor Erstnutzung insatllieren
library(gmodels)
Kontingenztabelle = CrossTable(Groesse, Note,
expected=TRUE,
prop.t=FALSE, prop.c=FALSE, prop.r=FALSE)

####weitere Beispiele: Gender-Effekt? Zufriedenheit?
# Test, ob Zufriedenheit und Note unabhängig (H0)
#Zufr = D[i,"MatheZufr"]
Gender = D[i,"Geschlecht"]
N = D[i,"NoteMathe"]
Note = cut(N, breaks=c(1,2,3,4,5), include.lowest = T)

#Tabelle = table(Zufr, Note)
Tabelle = table(Gender, Note)
###install.packages("gmodels") #Paket vor Erstnutzung insatllieren
library(gmodels)
#Kontingenztabelle = CrossTable(Zufr, Note, expected=TRUE, prop.t=FALSE,
prop.c=FALSE, prop.r=FALSE)
Kontingenztabelle = CrossTable(Gender, Note,

```

```
expected=TRUE,  
prop.t=FALSE, prop.c=FALSE, prop.r=FALSE)
```