



# Allgemeines Lineares Modell

BSc Psychologie, SoSe 2026

Joram Soch

## (9) Einstichproben-T-Tests

# Überblick

## Modul B2: Inferenzstatistik | Allgemeines Lineares Modell

Datum	Einheit	Do, 11-15 (ca. 11:15-14:00)	
09.04.2026	Grundlagen	(0) Formalia	(1) Regression
16.04.2026	Grundlagen	(2) Korrelation	
23.04.2026	Grundlagen	(3) Matrizen	
30.04.2026	Grundlagen / Theorie	(4) Normalverteilungen	(5) Modellformulierung
07.05.2026	Theorie	(6) Parameterschätzung	
14.05.2026	– Feiertag –	– keine Vorlesung –	
21.05.2026	Theorie	(7) T-Statistiken	
28.05.2026	Theorie	(8) F-Statistiken	
04.06.2026	Anwendung	(9) Einstichproben-T-Tests	(10) Zweistichproben-T-Tests
11.06.2026	Anwendung	(11) Einfaktorielle Varianzanalyse	
18.06.2026	Anwendung	(12) Zweifaktorielle Varianzanalyse	– Vorlesung online –
25.06.2026	Anwendung	(13) Partielle Korrelation	
02.07.2026	Anwendung	(14) Multiple Regression	
09.07.2026	Anwendung	(15) Kovarianzanalyse	
17.07.2026	Klausurtermin		
Februar 2027	Klausurwiederholungstermin		

# Überblick

## Kontinuum von ALM-Designs

Extremszenario (1) Die Erwartungswerte aller Datenvariablen sind identisch.

$$\begin{aligned} y_i &\sim N(\mu, \sigma^2) \quad \text{u.i.v. für } i = 1, \dots, n \Leftrightarrow \\ y &= X\beta + \varepsilon, \quad X := \mathbf{1}_n \in \mathbb{R}^{n \times 1}, \quad \beta := \mu \in \mathbb{R}, \quad \varepsilon \sim N(0_n, \sigma^2 I_n) \end{aligned} \quad (1)$$

⇒ Jegliche Datenvariabilität wird dem Fehlerterm zugeschrieben.

⇒ Es gilt  $\hat{\beta} = (\mathbf{1}_n^T \mathbf{1}_n)^{-1} \mathbf{1}_n^T y = \bar{y}$  und  $\hat{\sigma}^2 = \frac{1}{n-p} (y - \mathbf{1}_n \bar{y})^T (y - \mathbf{1}_n \bar{y}) = s_y^2$ .

Extremszenario (2) Die Erwartungswerte aller Datenvariablen sind paarweise verschieden.

$$\begin{aligned} y_i &\sim N(\mu_i, \sigma^2) \quad \text{u.v. für } i = 1, \dots, n \Leftrightarrow \\ y &= X\beta + \varepsilon, \quad X := I_n \in \mathbb{R}^{n \times n}, \quad \beta := (\mu_1, \dots, \mu_n)^T \in \mathbb{R}^n, \quad \varepsilon \sim N(0_n, \sigma^2 I_n) \end{aligned} \quad (2)$$

⇒ Jegliche Datenvariabilität wird dem Erwartungswertparameter zugeschrieben.

⇒ Es gilt  $\hat{\beta} = (I_n^T I_n)^{-1} I_n^T y = y$  und  $\hat{\sigma}^2 = \frac{1}{n-p} (y - I_n y)^T (y - I_n y) = 0$ .

Beide Extremszenarien sind wissenschaftlich nicht ergiebig, da sie keine theoriegeleitete systematische Abhängigkeit zwischen unabhängigen und abhängigen Variablen (UV, AV) annehmen. Die im weiteren Verlauf betrachteten ALM-Designs liegen zwischen den beiden Extremszenarien und repräsentieren verschiedene Formen der systematischen Abhängigkeit zwischen UV und AV.

## Faktorielle und parametrische ALM-Designs

### Faktorielle ALM-Designs:

- Designmatrizen mit 1en und 0en, manchmal  $-1$ en.
- Betaparameter repräsentieren Erwartungswerte für Gruppen.
- Betaparameterschätzer repräsentieren Stichprobenmittel für Gruppen.
- $\Rightarrow$  T-Tests, einfaktorielle Varianzanalyse, zweifaktorielle Varianzanalyse

### Parametrische ALM-Designs:

- Designmatrizen besitzen Spalten mit kontinuierlichen reellen Werten.
- Die Designmatrixspalten werden *Regressoren*, *Prädiktoren*, oder *Kovariaten* genannt.
- Betaparameter repräsentieren Steigungsparameter.
- Betaparameterschätzer ergeben sich als normalisierte Kovarianzen von Regressoren und Daten.
- Es besteht ein enger Bezug zur Theorie der Korrelation.
- $\Rightarrow$  einfache lineare Regression, multiple lineare Regression

### Faktoriell-parametrische ALM-Designs:

- Designmatrizen mit mehreren faktoriellen und parametrischen Werten.
- Die parametrischen Regressoren werden oft als kontrollierte Kovariaten betrachtet.
- $\Rightarrow$  Kovarianzanalyse, (partielle Korrelation)

## ALM-Designs als Hypothesentestverfahren\*

Testen von Unterschiedshypothesen:

- Einstichproben-T-Tests
- Zweistichproben-T-Tests
- einfaktorielle Varianzanalyse
- zweifaktorielle Varianzanalyse
- Kovarianzanalyse

Testen von Zusammenhangshypothesen:

- einfache lineare Regression/Korrelation
- multiple lineare Regression/partielle Korrelation

\* Diese Sichtweise wird durch Prof. Ostwald nicht favorisiert.

## T-Tests

Es gibt viele T-Test-Varianten, jeweils mit eigenen Testgütefunktionen.

Wir fokussieren hier auf die Darstellung von T-Tests als Spezialfällen des ALMs.

Wir behandeln im Detail:

- Einstichproben-T-Tests mit einfacher Nullhypothese und ungerichteter Alternativhypothese.
- Zweistichproben-T-Tests bei unabhängigen Stichproben unter Annahme identischer Varianzen mit einfacher Nullhypothese und ungerichteter Alternativhypothese (siehe Einheit (10) in *Allgemeines Lineares Modell*)

Wir behandeln nicht:

- T-Tests mit gerichteten Hypothesen oder einfachen Null- und Alternativhypothesen.
- Zweistichproben-T-Tests bei Annahme verschiedener Varianzen (Behrens-Fischer-Problem).
- Zweistichproben T-Tests bei abhängigen Stichproben.

---

Anwendungsszenario

Modellformulierung

Modellschätzung

Modellevaluation

Anwendung/Praxis

Selbstkontrollfragen

---

## **Anwendungsszenario**

Modellformulierung

Modellschätzung

Modellevaluation

Anwendung/Praxis

Selbstkontrollfragen

**Eine Gruppe** (Stichprobe) randomisierter experimenteller Einheiten.

Annahme der unabhängigen und identischen Normalverteilung  $N(\mu, \sigma^2)$ .

$\mu$  und  $\sigma^2$  unbekannt.

Quantifizieren der Unsicherheit beim inferentiellen Vergleich von  $\mu$  mit  $\mu_0$  beabsichtigt.

## Anwendungsbeispiele

Pre-Post-Psychotherapie: BDI-Differenzanalyse einer Gruppe von Patient:innen

- $\mu \neq \mu_0 := 0 \Rightarrow$  Evidenz für Depressionssymptomatikveränderung

Gruppenanalysen mit *Wechsler Adult Intelligence Scale* (WAIS)

- $\mu \neq \mu_0 := 100 \Rightarrow$  Evidenz für über- oder unterdurchschnittliche WAIS-Performanz

Gruppenanalysen in der funktionellen Kernspintomographie (fMRT)

- $\mu > \mu_0 := 0 \Rightarrow$  Evidenz für regionale Gehirnaktivierung

## Anwendungsbeispiel



Wir nehmen an, dass die Datenpunkte unabhängige und identisch verteilte (u.i.v.) Realisierungen von ZVen  $y_i \sim N(\mu, \sigma^2)$  sind und nehmen weiter an, dass wir sind an der Quantifizierung der Unsicherheit beim inferentiellen Vergleich des wahren, aber unbekanntem Erwartungswertparameters  $\mu$  im Sinne eines Hypothesentests interessiert sind.

---

Anwendungsszenario

**Modellformulierung**

Modellschätzung

Modellevaluation

Anwendung/Praxis

Selbstkontrollfragen

## Definition (Einstichproben-T-Test-Modell)

$y_i, i = 1, \dots, n$  seien Zufallsvariablen, die die  $n$  Datenpunkte eines Anwendungsszenarios für den Einstichproben-T-Test modellieren. Dann hat das *Einstichproben-T-Test-Modell* die strukturelle Form

$$y_i = \mu + \varepsilon_i \quad \text{mit} \quad \varepsilon_i \sim N(0, \sigma^2) \quad \text{u.i.v. für} \quad i = 1, \dots, n \quad \text{mit} \quad \mu \in \mathbb{R} \quad \text{und} \quad \sigma^2 > 0, \quad (3)$$

die Datenverteilungsform

$$y_i \sim N(\mu, \sigma^2) \quad \text{u.i.v. für} \quad i = 1, \dots, n \quad \text{mit} \quad \mu \in \mathbb{R} \quad \text{und} \quad \sigma^2 > 0, \quad (4)$$

und für den Datenvektor  $y = (y_1, \dots, y_n)^T$  die Designmatrixform

$$y = X\beta + \varepsilon \quad \text{mit} \quad X := \mathbf{1}_n \in \mathbb{R}^{n \times 1}, \quad \beta := \mu \in \mathbb{R}, \quad \varepsilon \sim N(0_n, \sigma^2 I_n), \quad \text{und} \quad \sigma^2 > 0. \quad (5)$$

### Bemerkungen

- Das Modell ist identisch mit dem Modell unabhängiger und identisch normalverteilter Zufallsvariablen.
- Die Äquivalenz der drei Modellformen wurde bereits diskutiert (vgl. Einheit (5) in *Allgemeines Lineares Modell*).
- Die Anzahl der Betaparameter ist  $p = 1$ .

# Modellformulierung

---

Designmatrix des Einstichproben-T-Test-Modells ( $n = 20$ ,  $p = 1$ )




## Datensimulation (vgl. Einheit (5) in *Allgemeines Lineares Modell*)

```
# Modellformulierung
library(MASS) # multivariate Normalverteilung
n = 20 # Anzahl von Datenpunkten
p = 1 # Anzahl von Betaparametern
X = matrix(rep(1,n), nrow = n) # n x p Designmatrix
I_n = diag(n) # n x n Einheitsmatrix
beta = 5 # wahrer, aber unbekannter Betaparameter
sigsqr = 14 # wahrer, aber unbekannter Varianzparameter

# Datenrealisierung
y = mvrnorm(1, X %*% beta, sigsqr*I_n) # eine Realisierung des n-dimensionalen ZVs y
print(y)
```

```
[1] 6.3323967 6.8906198 3.8857604 9.2885623 -2.8381190 2.8728300
[7] -0.8463879 4.3471780 13.2448606 9.3029791 -2.7044583 3.0756980
[13] 2.4637458 1.0785485 4.4239466 4.8236078 2.5477300 7.1895089
[19] 2.3182476 9.2401002
```

---

Anwendungsszenario

Modellformulierung

**Modellschätzung**

Modellevaluation

Anwendung/Praxis

Selbstkontrollfragen

## Theorem (Parameterschätzung im Einstichproben-T-Test-Modell)

Gegeben sei die Designmatrixform des Einstichproben-T-Test-Modells. Dann ergeben sich für den Betaparameterschätzer

$$\hat{\beta} = \frac{1}{n} \sum_{i=1}^n y_i =: \bar{y} \quad (6)$$

und für den Varianzparameterschätzer

$$\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2 =: s_y^2. \quad (7)$$

### Bemerkungen

- Die Formen von  $\hat{\beta}$  und  $\hat{\sigma}^2$  wurden bereits hergeleitet (siehe Einheit (6) in *Allgemeines Lineares Modell*).
- $\bar{y}$  und  $s_y^2$  bezeichnen das Stichprobenmittel und die Stichprobenvarianz der  $y_1, \dots, y_n$ .

# Modellschätzung

```
# Daten einlesen
fname      = "Daten/T-Tests_Daten.csv"           # Dateiname
D          = read.table(fname, sep = ",", header = TRUE) # Dataframe
y          = D$dBDI[D$Setting == "F2F"]          # BDI-Differenzwerte in der F2F-Gruppe

# Modellformulierung
n          = length(y)                          # Anzahl Datenpunkte
p          = 1                                  # Anzahl Betaparameter
X          = matrix(rep(1,n), nrow = n)         # Designmatrix

# Modellschätzung
beta_hat   = solve(t(X) %*% X) %*% t(X) %*% y   # Betaparameterschätzer
eps_hat    = y - X %*% beta_hat                # Residuenvektor
sigsqr_hat = (t(eps_hat) %*% eps_hat) / (n-p)   # Varianzparameterschätzer

# Ausgabe
cat( "hat{beta}  : ", beta_hat,                # Betaparameterschätzer
     "\nbar{y}   : ", mean(y),                # Stichprobenmittel
     "\nhat{sigsqr} : ", sigsqr_hat,          # Varianzparameterschätzer
     "\ns_y^2    : ", var(y))                 # Stichprobenvarianz

hat{beta}  : 3.925
bar{y}     : 3.925
hat{sigsqr} : 19.40449
s_y^2     : 19.40449
```

---

Anwendungsszenario

Modellformulierung

Modellschätzung

**Modellevaluation**

Anwendung/Praxis

Selbstkontrollfragen

## Hypothesenszenarien

Einfache Nullhypothese, einfache Alternativhypothese  $H_0 : \mu = \mu_0$ ,  $H_1 : \mu = \mu_1$

- theoretisch wichtiges Szenario (Neymann-Pearson-Lemma)
- praktische Relevanz eher gering

Einfache Nullhypothese, zusammengesetzte Alternativhypothese  $H_0 : \mu = \mu_0$ ,  $H_1 : \mu \neq \mu_0$

- zweiseitiger Einstichproben-T-Test mit ungerichteter Hypothese
- ungerichtete Fragestellung nach einem Unterschied

Zusammengesetzte Nullhypothese/Alternativhypothese  $H_0 : \mu \leq \mu_0$ ,  $H_1 : \mu > \mu_0$

- einseitiger Einstichproben-T-Test mit gerichteter Hypothese
- gerichtete Fragestellung nach einem positiven Unterschied

Zusammengesetzte Nullhypothese/Alternativhypothese  $H_0 : \mu \geq \mu_0$ ,  $H_1 : \mu < \mu_0$

- gerichtete Fragestellung nach einem negativen Unterschied
- qualitativ äquivalente Theorie zum umgekehrten Fall

## Hypothesenszenarien

Einfache Nullhypothese, einfache Alternativhypothese  $H_0 : \mu = \mu_0, H_1 : \mu = \mu_1$

- theoretisch wichtiges Szenario (Neymann-Pearson Lemma)
- praktische Relevanz eher gering

Einfache Nullhypothese, zusammengesetzte Alternativhypothese  $H_0 : \mu = \mu_0, H_1 : \mu \neq \mu_0$

- zweiseitiger Einstichproben-T-Test mit ungerichteter Hypothese
- ungerichtete Fragestellung nach einem Unterschied

Zusammengesetzte Nullhypothese/Alternativhypothese  $H_0 : \mu \leq \mu_0, H_1 : \mu > \mu_0$

- einseitiger Einstichproben-T-Test mit gerichteter Hypothese
- gerichtete Fragestellung nach einem positiven Unterschied

Zusammengesetzte Nullhypothese/Alternativhypothese  $H_0 : \mu \geq \mu_0, H_1 : \mu < \mu_0$

- gerichtete Fragestellung nach einem negativen Unterschied
- qualitativ äquivalente Theorie zum umgekehrten Fall

Gliederung (vgl. Einheit (12), um 01:58:00 in *Wahrscheinlichkeitstheorie und Frequentistische Inferenz*)

- (1) Statistisches Modell ✓
- (2) Testhypothesen ✓
- (3) Teststatistik
- (4) Test
- (5) Analyse der Testgütefunktion
- (6) Testumfangkontrolle
- (7) p-Wert
- (8) Analyse der Powerfunktion

### Bezeichnungskonventionen für $t$ -Zufallsvariablen

- Für eine (nichtzentrale)  $t$ -Zufallsvariable  $\xi$  schreiben wir  $\xi \sim t(n)$  (oder  $\xi \sim t(\delta, n)$ ).
- Die WDF einer (nichtzentralen)  $t$ -Zufallsvariable ist  $t(\cdot; n)$  (oder  $t(\cdot; \delta, n)$ ).
- Die KVF einer (nichtzentralen)  $t$ -Zufallsvariable ist  $\psi(\cdot; n)$  (oder  $\psi(\cdot; \delta, n)$ ).
- Die Teststatistik eines T-Test-Designs/Hypothesentests bezeichnen wir mit  $T$ .
- Die Realisierung der T-Teststatistik für einen Datensatz bezeichnen wir mit  $t$ .

### Theorem (T-Teststatistik des Einstichproben-T-Tests)

Gegeben sei die Designmatrixform des Einstichproben-T-Test-Modells. Dann ergibt sich für die T-Teststatistik mit

$$c := 1 \quad \text{und} \quad \beta_0 =: \mu_0, \quad (8)$$

dass

$$T = \sqrt{n} \left( \frac{\bar{y} - \mu_0}{s_y} \right) \quad (9)$$

und es gilt

$$T \sim t(\delta, n - 1) \quad \text{mit} \quad \delta = \sqrt{n} \left( \frac{\mu - \mu_0}{\sigma} \right). \quad (10)$$

#### Bemerkungen

- Das Theorem basiert auf der T-Statistik im Rahmen des ALM.
- Wir erinnern an das verwandte populäre und von der Stichprobengröße unabhängige Effektstärke-Maß *Cohen's d* bei Einstichproben-T-Test-Designs,

$$d := \frac{\bar{y}}{s_y}. \quad (11)$$

- Offenbar gilt für *Cohen's d*, dass mit  $\mu_0 := 0$

$$T = \sqrt{n}d \quad \Leftrightarrow \quad d = T/\sqrt{n}. \quad (12)$$

### Beweis

Mit dem Theorem zur Verteilung der T-Statistik (siehe Einheit (7) in *Allgemeines Lineares Modell*) gilt

$$T = \frac{c^T \hat{\beta} - c^T \beta_0}{\sqrt{\hat{\sigma}^2 c^T (X^T X)^{-1} c}} = \frac{1^T \bar{y} - 1^T \mu_0}{\sqrt{s_y^2 1^T (1_n^T 1_n)^{-1} 1}} = \sqrt{n} \left( \frac{\bar{y} - \mu_0}{s_y} \right). \quad (13)$$

Weiterhin gilt mit demselben Theorem

$$\delta = \frac{c^T \beta - c^T \beta_0}{\sqrt{\sigma^2 c^T (X^T X)^{-1} c}} = \frac{1^T \mu - 1^T \mu_0}{\sqrt{\sigma^2 1^T (1_n^T 1_n)^{-1} 1}} = \sqrt{n} \left( \frac{\mu - \mu_0}{\sigma} \right). \quad (14)$$

□

### Definition (Zweiseitiger Einstichproben-T-Tests)

Gegeben sei das Einstichproben-T-Test-Modell. Für ein  $\mu_0 \in \mathbb{R}$  seien die einfache Nullhypothese und die zusammengesetzte Alternativhypothese als

$$H_0 : \mu = \mu_0 \quad \text{und} \quad H_1 : \mu \neq \mu_0 \quad (15)$$

definiert. Weiterhin sei die T-Teststatistik definiert als

$$T := \sqrt{n} \left( \frac{\bar{y} - \mu_0}{s_y} \right) \quad (16)$$

Dann ist der *zweiseitige Einstichproben-T-Tests* definiert als der kritische-Wert-basierte Test

$$\phi(y) := 1_{\{|T| \geq k\}} = \begin{cases} 1 & |T| \geq k \\ 0 & |T| < k \end{cases}. \quad (17)$$

#### Bemerkungen

- Ausführlicher handelt es sich um den *zweiseitigen Einstichproben-T-Test mit ungerichteter Hypothese*.

### Theorem (Testgütefunktion)

$\phi$  sei der im obigen Testszenario definierte Test. Dann ist die Testgütefunktion von  $\phi$  gegeben durch

$$q_\phi : \mathbb{R} \rightarrow [0, 1], \mu \mapsto q_\phi(\mu) := 1 - \psi(k; \delta, n - 1) + \psi(-k; \delta, n - 1) \quad (18)$$

wobei  $\psi(\cdot; \delta, n - 1)$  die KVF der nichtzentralen  $t$ -Verteilung mit Nichtzentralitätsparameter


$$\delta := \sqrt{n} \left( \frac{\mu - \mu_0}{\sigma} \right) \quad (19)$$

und Freiheitsgradparameter  $n - 1$  bezeichnet.

## Modellevaluation (5) Analyse der Testgütefunktion

Testgütefunktion  $q_\phi$  für  $\sigma^2 = 9, \mu_0 = 4, n = 12$  und  $k = 1, 2, 3$ .

$$q_\phi(\mu) = \mathbb{P}_\mu(\phi = 1)$$



## Modellevaluation (5) Analyse der Testgütefunktion

### Beweis

Die Testgütefunktion des betrachteten Test im vorliegenden Testszenario ist definiert als

$$q_\phi : \mathbb{R} \rightarrow [0, 1], \mu \mapsto q_\phi(\mu) := \mathbb{P}_\mu(\phi = 1). \quad (20)$$

Da die Wahrscheinlichkeiten für  $\phi = 1$  und dafür, dass die zugehörige Teststatistik im Ablehnungsbereich des Tests liegt, gleich sind, benötigen wir also zunächst die Verteilung der Teststatistik. Wir haben oben bereits gesehen, dass die T-Teststatistik

$$T := \sqrt{n} \left( \frac{\bar{y} - \mu_0}{s_y} \right) \quad (21)$$

unter der Annahme  $y_i \sim N(\mu, \sigma^2)$  u.i.v. für  $i = 1, \dots, n$  nach einer nichtzentralen  $t$ -Verteilung  $t(\delta, n - 1)$  mit Nichtzentralitätsparameter

$$\delta = \sqrt{n} \left( \frac{\mu - \mu_0}{\sigma} \right) \quad (22)$$

verteilt ist. Der Ablehnungsbereich des zweiseitigen T-Tests ergibt sich, wie in ähnlicher Form bei der Betrachtung des zweiseitigen Z-Tests gesehen, zu

$$A = ] - \infty, -k] \cup ]k, \infty[. \quad (23)$$

### Beweis (fortgeführt)

Mit diesem Ablehnungsbereich ergibt sich dann

$$\begin{aligned}q_{\phi}(\mu) &= \mathbb{P}_{\mu}(\phi = 1) \\&= \mathbb{P}_{\mu}(T \in ]-\infty, -k] \cup ]k, \infty[) \\&= \mathbb{P}_{\mu}(T \in ]-\infty, -k]) + \mathbb{P}_{\mu}(T \in [k, \infty[) \\&= \mathbb{P}_{\mu}(T \leq -k) + \mathbb{P}_{\mu}(T \geq k) \\&= \mathbb{P}_{\mu}(T \leq -k) + (1 - \mathbb{P}_{\mu}(T \leq k)) \\&= 1 - \mathbb{P}_{\mu}(T \leq k) + \mathbb{P}_{\mu}(T \leq -k) \\&= 1 - \psi(k; \delta, n - 1) + \psi(-k; \delta, n - 1),\end{aligned}\tag{24}$$

wobei  $\psi(\cdot; \delta, n - 1)$  die KVF der nichtzentralen T-Verteilung mit Nichtzentralitätsparameter  $\delta$  und Freiheitsgradparameter  $n - 1$  bezeichnet.  $\square$

### Theorem (Testumfangkontrolle)



$\phi$  sei der im obigen Testszenario definierte Test. Dann ist  $\phi$  ein Level- $\alpha_0$ -Test mit Testumfang  $\alpha_0$ , wenn der kritische Wert definiert ist durch

$$k_{\alpha_0} := \psi^{-1}\left(1 - \frac{\alpha_0}{2}; n - 1\right), \quad (25)$$

wobei  $\psi^{-1}(\cdot; n - 1)$  die inverse KVF der  $t$ -Verteilung mit  $n - 1$  Freiheitsgraden ist.

## Modellevaluation (6) Testumfangkontrolle

Wahl von  $k_{\alpha_0} := \psi^{-1}(1 - \alpha_0/2; n - 1)$  mit  $n = 12$ ,  $\alpha_0 := 0.05$  und Ablehnungsbereich



## Modellevaluation (6) Testumfangkontrolle

### Beweis

Damit der betrachtete Test ein Level- $\alpha_0$ -Test ist, muss bekanntlich  $q_\phi(\mu) \leq \alpha_0$  für alle  $\mu \in \{\mu_0\}$ , also hier  $q_\phi(\mu_0) \leq \alpha_0$ , gelten. Weiterhin ist der Testumfang des betrachteten Tests durch  $\alpha = \max_{\mu \in \{\mu_0\}} q_\phi(\mu)$ , also hier durch  $\alpha = q_\phi(\mu_0)$  gegeben. Wir müssen also zeigen, dass die Wahl von  $k_{\alpha_0}$  garantiert, dass  $\phi$  ein Level- $\alpha_0$ -Test mit Testumfang  $\alpha_0$  ist. Dazu merken wir zunächst an, dass für  $\mu = \mu_0$  gilt, dass

$$\begin{aligned}q_\phi(\mu_0) &= 1 - \psi(k; \delta, n - 1) + \psi(-k; \delta, n - 1) \\ &= 1 - \psi(k; 0, n - 1) + \psi(-k; 0, n - 1) \\ &= 1 - \psi(k; n - 1) + \psi(-k; n - 1),\end{aligned}\tag{26}$$

wobei  $\psi(\cdot; \delta, n - 1)$  und  $\psi(\cdot; n - 1)$  die KVF der nichtzentralen  $t$ -Verteilung mit Nichtzentralitätsparameter  $\delta$  und Freiheitsgradparameter  $n - 1$  bzw. der  $t$ -Verteilung mit Freiheitsgradparameter  $n - 1$  bezeichnen. Mit  $k := k_{\alpha_0}$  gilt dann

$$\begin{aligned}q_\phi(\mu_0) &= 1 - \psi(k_{\alpha_0}; n - 1) + \psi(-k_{\alpha_0}; n - 1) \\ &= 1 - \psi(k_{\alpha_0}; n - 1) + (1 - \psi(k_{\alpha_0}; n - 1)) \\ &= 2(1 - \psi(k_{\alpha_0}; n - 1)) \\ &= 2 \left( 1 - \psi \left( \psi^{-1} (1 - \alpha_0/2; n - 1); n - 1 \right) \right) \\ &= 2(1 - (1 - \alpha_0/2)) \\ &= \alpha_0,\end{aligned}\tag{27}$$

wobei die zweite Gleichung mit der Symmetrie der  $t$ -Verteilung folgt. Es folgt also direkt, dass bei der Wahl von  $k = k_{\alpha_0}$ ,  $q_\phi(\mu_0) \leq \alpha_0$  ist und der betrachtete Test somit ein Level- $\alpha_0$ -Test ist. Weiterhin folgt direkt, dass der Testumfang des betrachteten Tests bei der Wahl von  $k = k_{\alpha_0}$  gleich  $\alpha_0$  ist.  $\square$

## Praktisches Vorgehen

- Man nimmt an, dass ein Datensatz  $y_1, \dots, y_n$  eine Realisation von  $y_i \sim N(\mu, \sigma^2)$  u.i.v. für  $i = 1, \dots, n$  mit unbekanntem Parametern  $\mu$  und  $\sigma^2 > 0$  ist.
- Man möchte entscheiden ob für ein  $\mu_0 \in \mathbb{R}$  eher  $H_0 : \mu = \mu_0$  oder  $H_1 : \mu \neq \mu_0$  zutrifft.
- Man wählt ein Signifikanzniveau  $\alpha_0$  und bestimmt den zugehörigen Freiheitsgradparameter-abhängigen kritischen Wert  $k_{\alpha_0}$ . Zum Beispiel gilt bei Wahl von  $\alpha_0 := 0.05$  und  $n = 12$ , dass  $k_{0.05} = \psi^{-1}(1 - 0.05/2; 12 - 1) \approx 2.20$  ist.
- Anhand von  $n, \mu_0, \bar{y}$  und  $s_y$  berechnet man die Realisierung der T-Teststatistik

$$t := \sqrt{n} \left( \frac{\bar{y} - \mu_0}{s_y} \right) \quad (28)$$

- Wenn  $t$  größer-gleich  $k_{\alpha_0}$  ist oder wenn  $t$  kleiner-gleich  $-k_{\alpha_0}$  ist, lehnt man die Nullhypothese ab, andernfalls lehnt man sie nicht ab.
- Die oben entwickelte Theorie garantiert dann, dass man in höchstens  $\alpha_0 \cdot 100$  von 100 Fällen die Nullhypothese fälschlicherweise ablehnt.

### Bestimmung des p-Wertes

- Per Definition ist der p-Wert das kleinste Signifikanzlevel  $\alpha_0$ , bei welchem man die Nullhypothese basierend auf einem vorliegendem Wert der Teststatistik ablehnen würde.
- Bei  $T = t$  würde  $H_0$  für jedes  $\alpha_0$  mit  $|t| \geq \psi^{-1}(1 - \alpha_0/2; n - 1)$  abgelehnt werden. Für diese  $\alpha_0$  gilt, wie unten gezeigt,

$$\alpha_0 \geq 2\mathbb{P}(T \geq |t|). \quad (29)$$

- Das kleinste  $\alpha_0 \in [0, 1]$  mit  $\alpha_0 \geq 2\mathbb{P}(T \geq |t|)$  ist dann  $\alpha_0 = 2\mathbb{P}(T \geq |t|)$ , also folgt

$$\text{p-Wert} = 2\mathbb{P}(T \geq |t|) = 2(1 - \psi(|t|; n - 1)). \quad (30)$$

- Im Gegensatz zum Z-Test hängt bei T-Tests der p-Wert auch von der Stichprobengröße ab.
- Zum Beispiel ist für  $t = 2.00$  und  $n = 10$  der p-Wert 0.076, für  $t = 2.00$  und  $n = 100$  ist der p-Wert dagegen 0.048.

## Bestimmung des p-Wertes

- Es bleibt zu zeigen, dass gilt

$$|t| \geq \psi^{-1}(1 - \alpha_0/2; n - 1) \Leftrightarrow \alpha_0 \geq 2\mathbb{P}(T \geq |t|) . \quad (31)$$

- Dies aber folgt aus

$$\begin{aligned} |t| &\geq \psi^{-1}\left(1 - \frac{\alpha_0}{2}; n - 1\right) \\ \Leftrightarrow \psi(|t|; n - 1) &\geq \psi\left(\psi^{-1}\left(1 - \frac{\alpha_0}{2}; n - 1\right); n - 1\right) \\ \Leftrightarrow \psi(|t|; n - 1) &\geq 1 - \frac{\alpha_0}{2} \\ \Leftrightarrow \mathbb{P}(T \leq |t|) &\geq 1 - \frac{\alpha_0}{2} \\ \Leftrightarrow \frac{\alpha_0}{2} &\geq 1 - \mathbb{P}(T \leq |t|) \\ \Leftrightarrow \frac{\alpha_0}{2} &\geq \mathbb{P}(T \geq |t|) \\ \Leftrightarrow \alpha_0 &\geq 2\mathbb{P}(T \geq |t|) . \end{aligned} \quad (32)$$

## Modellevaluation (8) Analyse der Powerfunktion

---

Wir betrachten die Testgütefunktion

$$q_\phi : \mathbb{R} \rightarrow [0, 1], \mu \mapsto q_\phi(\mu) := 1 - \psi(k_{\alpha_0}; \delta, n - 1) + \psi(-k_{\alpha_0}; \delta, n - 1) \quad (33)$$

bei kontrolliertem Testumfang, also für  $k_{\alpha_0} := \psi^{-1}(1 - \alpha_0/2; n - 1)$  mit festem  $\alpha_0$  als Funktion des Nichtzentralitätsparameters und des Stichprobenumfangs. Namentlich hängt hier  $k_{\alpha_0}$  sowohl von  $\alpha_0$  als auch von  $n$  ab.


Es ergibt sich die bivariate reellwertige Funktion

$$\pi : \mathbb{R} \times \mathbb{N} \rightarrow [0, 1], (\delta, n) \mapsto \pi(\delta, n) := 1 - \psi(k_{\alpha_0}; \delta, n - 1) + \psi(-k_{\alpha_0}; \delta, n - 1) \quad (34)$$

Bei festgelegten  $\alpha_0$  hängt die Powerfunktion des zweiseitigen T-Tests mit einfacher Nullhypothese also vom unbekanntem Wert  $\delta$  und von der Stichprobengröße  $n$  ab. Wir visualisieren diese Abhängigkeiten untenstehend.


## Modellevaluation (8) Analyse der Powerfunktion

Powerfunktion für  $\alpha_0 = 0.05$







## Modellevaluation (8) Analyse der Powerfunktion

Powerfunktion für  $\alpha_0 = 0.001$



# Modellevaluation (8) Analyse der Powerfunktion

Powerfunktionen für  $\mu_0 = 0$



### Praktisches Vorgehen

Mit größerem  $n$  steigt die Powerfunktion des Tests an:

- Ein großer Stichprobenumfang ist besser als ein kleiner Stichprobenumfang.
- Kosten für die Erhöhung des Stichprobenumfangs werden aber nicht berücksichtigt.

⇒ Die Theorie statistischer Hypothesentests ist nicht besonders lebensnah.

Die Powerfunktion hängt vom wahren, aber unbekanntem Wert  $\delta = \sqrt{n} \left( \frac{\mu - \mu_0}{\sigma} \right)$  ab.


⇒ Wenn man  $\delta$  schon kennen würde, würde man den Test nicht durchführen.

Generell wird folgendes Vorgehen favorisiert:

- Man legt das Signifikanzniveau  $\alpha_0$  fest und evaluiert die Powerfunktion.
- Man wählt einen Mindestparameterwert  $\delta^*$ , den man mit  $\pi(\delta, n) = b$  detektieren möchte.
- Ein konventioneller Wert ist  $b = 0.8$ .
- Man liest die für  $\pi(\delta = \delta^*, n) = b$  nötige Stichprobengröße  $n$  ab.

## Modellevaluation (8) Analyse der Powerfunktion

### Praktisches Vorgehen



---

Anwendungsszenario

Modellformulierung

Modellschätzung

Modellevaluation

**Anwendung/Praxis**

Selbstkontrollfragen

## Anwendungsbeispiel



Wir nehmen an, dass die Datenpunkte unabhängige und identisch verteilte (u.i.v.) Realisierungen von ZVen  $y_i \sim N(\mu, \sigma^2)$  sind und nehmen weiter an, dass wir sind an der Quantifizierung der Unsicherheit beim inferentiellen Vergleich des wahren, aber unbekanntem Erwartungswertparameters  $\mu$  im Sinne eines Hypothesentests interessiert sind.

## Daten einlesen

```
fname = "Daten/T-Tests_Daten.csv"  
D = read.table(fname, sep = ",", header = TRUE)
```

X	ID	Setting	PreBDI	PostBDI	dBDI
1	1	F2F	29	25	4
2	2	F2F	32	27	5
3	3	F2F	28	31	-3
4	4	F2F	36	22	14
5	5	F2F	32	29	3
6	6	F2F	28	28	0
7	7	F2F	33	30	3
8	8	F2F	33	26	7
9	9	F2F	33	28	5
10	10	F2F	30	28	2
11	11	F2F	36	25	11
12	12	F2F	32	31	1
13	13	F2F	29	31	-2
14	14	F2F	24	29	-5
15	15	F2F	35	32	3
16	16	F2F	31	29	2
17	17	F2F	31	23	8
18	18	F2F	34	25	9
19	19	F2F	34	23	11
20	20	F2F	33	26	7
21	21	F2F	34	25	9
22	22	F2F	33	27	6
23	23	F2F	31	24	7
24	24	F2F	25	27	-2
25	25	F2F	33	25	8
26	26	F2F	31	33	-2
27	27	F2F	31	29	2
28	28	F2F	26	30	-4
29	29	F2F	29	28	1
30	30	F2F	32	32	0
31	31	F2F	35	25	10
32	32	F2F	31	26	5
33	33	F2F	32	32	0
34	34	F2F	31	25	6
35	35	F2F	27	26	1
36	36	F2F	30	26	4
37	37	F2F	30	26	4
38	38	F2F	31	26	5
39	39	F2F	34	29	5
40	40	F2F	33	26	7

# Anwendung/Praxis

```
# Datensatz von Interesse
BDI_F2F      = D$dBDI[D$Setting == "F2F"]

# Histogrammparameter
h            = 1
b_0         = min(BDI_F2F)
b_k         = max(BDI_F2F)
k           = ceiling((b_k - b_0)/h)
b           = seq(b_0, b_k, by = h)
ylimits     = c(0,0.15)
xlimits     = c(-5,15)

# Abbildungsparameter
par(
  mfcol      = c(1,1),
  family     = "sans",
  pty        = "s",
  bty        = "l",
  las        = 1,
  xaxs       = "i",
  yaxs       = "i",
  font.main  = 1,
  cex        = 1,
  cex.main   = 1)

# Histogramm
hist(BDI_F2F,
     breaks = b,
     freq   = F,
     xlim   = xlimits,
     ylim   = ylimits,
     xlab   = TeX("$\\Delta$ BDI$"),
     ylab   = "geschätzte Wahrscheinlichkeit",
     main   = "")

# Speichern
dev.copy2pdf(
  file      = "Abbildungen/F2F_histogramm.pdf",
  width     = 4,
  height    = 4)

# BDI-Differenzwerte in der F2F-Gruppe

# gewünschte Klassenbreite
# b_0
# b_k
# Anzahl der Klassen
# Klassen [b_0, ..., b_k]
# y-Achsenlimits
# x-Achsenlimits

# für Details siehe ?par
# 1 x 1 Panelstruktur
# Serif-freier Fonttyp
# quadratische Abbildungsregion
# L-förmige Box
# horizontale Achsenbeschriftung
# x-Achse bei y = 0
# y-Achse bei x = 0
# Titel nicht fett
# Textvergrößerungsfaktor
# Titeltextvergrößerungsfaktor

# Delta-BDI_Werte von Therapiebedingung i
# Histogrammklassen
# normierte relative Häufigkeit
# x-Achsenlimits
# y-Achsenlimits
# x-Achsenbeschriftung
# y-Achsenbeschriftung
# Titelbeschriftung
```


## Anwendung/Praxis

```
# Einlesen der Daten
fname      = "Daten/T-Tests_Daten.csv"
D          = read.table(fname, sep = ",", header = TRUE)

# Initialisierung eines Dataframes
tp         = c("F2F")                # Therapiebedingungen
ntp        = length(tp)              # Anzahl Therapiebedingungen
S          = data.frame(              # Dataframe-Erzeugung
  n         = rep(NaN,ntp),           # Stichprobengrößen
  Max       = rep(NaN,ntp),           # Maxima
  Min       = rep(NaN,ntp),           # Minima
  Median    = rep(NaN,ntp),           # Mediane
  Mean      = rep(NaN,ntp),           # Mittelwerte
  Var       = rep(NaN,ntp),           # Varianzen
  Std       = rep(NaN,ntp),           # Standardabweichungen
  row.names = tp)                    # Therapiebedingungen

# Iterationen über Therapiebedingungen
for(i in 1:ntp){
  data     = D$dBDI[D$Setting == tp[i]] # Daten
  S$n[i]   = length(data)                # Stichprobengröße
  S$Max[i] = max(data)                    # Maxima
  S$Min[i] = min(data)                    # Minima
  S$Median[i] = median(data)              # Mediane
  S$Mean[i] = mean(data)                  # Mittelwerte
  S$Var[i]  = var(data)                   # Varianzen
  S$Std[i]  = sd(data)                    # Standardabweichungen
}
```

## Deskriptive Statistiken der negativen PostBDI-PreBDI-Differenzen bei Face-to-Face-Therapie



```
# Ausgabe  
print.AsIs(S)
```

	n	Max	Min	Median	Mean	Var	Std
F2F	40	14	-5	4	3.925	19.40449	4.405052

# Anwendung/Praxis

```
# Daten einlesen
fname      = "Daten/T-Tests_Daten.csv"
D          = read.table(fname, sep = ",", header = TRUE)
y          = D$dBDI[D$Setting == "F2F"]

# Modellformulierung
n          = length(y)
p          = 1
X          = matrix(rep(1,n), nrow = n)

# Parameterschätzung
beta_hat   = solve(t(X) %*% X) %*% t(X) %*% y
eps_hat    = y - X %*% beta_hat
sigsqr_hat = t(eps_hat) %*% eps_hat) / (n-p)

# Konfidenzintervall
delta      = 0.95
t_delta    = qt((1+delta)/2, n-1)
lambda     = diag(solve(t(X) %*% X))
kappa      = matrix(rep(NA,n*p*2), nrow = p)
for(j in 1:p){
  kappa[j,1] = beta_hat[j]-sqrt(sigsqr_hat*lambda[j])*t_delta
  kappa[j,2] = beta_hat[j]+sqrt(sigsqr_hat*lambda[j])*t_delta
}

# Hypothesentest
c          = matrix(c(1),nrow = p)
mu_0       = 0
alpha_0    = 0.05
k_alpha_0  = qt(1 - (alpha_0/2), n-1)
t_num      = t(c) %*% beta_hat - mu_0
t_den      = sqrt(sigsqr_hat %*% t(c)*solve(t(X) %*% X)%*%c)
t          = t_num/t_den
if(abs(t) >= k_alpha_0){phi = 1} else {phi = 0}
pval       = 2*(1 - pt(abs(t), n-1))
d          = t/sqrt(n)

# Dateiname
# Dataframe
# BDI-Differenzwerte in der F2F-Gruppe

# Anzahl Datenpunkte
# Anzahl Betaparameter
# n x p Designmatrix

# Betaparameterschätzer
# Residuenvektor
# Varianzparameterschätzer

# Konfidenzbedingung
# \Psi^{-1}((1+\delta)/2; n-1)
# \lambda_j Werte
# \beta_j Konfidenzintervall-Array
# Iteration über \beta_j
# untere KI-Grenze
# obere KI-Grenze

# Kontrastgewichtsvektor
# Nullhypothese
# Signifikanzniveau
# kritischer Wert
# T-Teststatistik-Zähler
# T-Teststatistik-Nenner
# T-Teststatistik
# Test 1_{|T(X)| >= k_alpha_0}
# p-Wert
# Cohen's d

fg         = 39
kappa_1    = 2.516196 5.333804
t          = 5.63532
alpha_0    = 0.05
k_alpha_0  = 2.022691
phi        = 1
p-Wert     = 1.662163e-06
Cohen's d  = 0.8910223
```

## Anwendungsszenario

```
# automatischer Einstichproben-T-Test
varphi = t.test(y,                                # Datensatz
               alternative = c("two.sided"),      # H_1: \mu \neq \mu_0
               mu          = 0,                  # \mu_0 (sic!)
               conf.level  = 1-alpha_0)         # \delta = 1 - \alpha_0

# Ausgabe
print(varphi)
```

### One Sample t-test

```
data: y
t = 5.6353, df = 39, p-value = 1.662e-06
alternative hypothesis: true mean is not equal to 0
95 percent confidence interval:
 2.516196 5.333804
sample estimates:
mean of x
 3.925
```


```
# genauere Ausgabe von t
paste(varphi[1]$statistic)
```

```
[1] "5.63531986397201"
```

```
# genauere Ausgabe von p
paste(varphi[3]$p.value)
```

```
[1] "1.66216308541e-06"
```

Datensatz: Zielzeiten beim Great 10k (08.10.2017), getrennt nach Altersklasse ( $n = 4883$ )




Einstichproben-T-Test: 10-km-Zeit, alle Teilnehmer ( $n = 4883$ )

```
# Daten extrahieren
D$T10k = t10_min # 10-km-Zeit [min]

# Einstichproben-T-Test (falsch)
n      = nrow(D) # Anzahl Datenpunkte
p      = 1       # Anzahl Regressoren
y      = matrix(D$T10k, nrow = n) # Datenvektor
X      = matrix(rep(1,n), ncol = p) # Designmatrix
```

```
Betaparameterschätzer      : 54.901
Varianzparameterschätzer  : 86.6
Einstichproben-T-Teststatistik : 412.257
Cohen's d                  : 5.9
p-Wert                     : 0
```

Datensatz: erste vs. zweite 5 km beim Great 10k (08.10.2017), alle Teilnehmer ( $n = 4883$ )



Einstichproben-T-Test: Differenz zweite minus erste 5 km, alle Teilnehmer ( $n = 4883$ )

```
# Daten extrahieren
D$T5k1 = t5_min           # erste 5 km [min]
D$T5k2 = t10_min-t5_min  # zweite 5 km [min]
D$Tdiff= D$T5k2 - D$T5k1 # Differenz [min]

# Einstichproben-T-Test (richtig)
n      = nrow(D)          # Anzahl Datenpunkte
p      = 1                # Anzahl Regressoren
y      = matrix(D$Tdiff, nrow = n) # Datenvektor
X      = matrix(rep(1,n), ncol = p) # Designmatrix
```

```
Betaparameterschätzer      : 0.708
Varianzparameterschätzer   : 2.208
Einstichproben-T-Teststatistik : 33.28
Cohen's d                   : 0.476
p-Wert                       : 0
```

---

Anwendungsszenario

Modellformulierung

Modellschätzung

Modellevaluation

Anwendung/Praxis

**Selbstkontrollfragen**

# Selbstkontrollfragen

---

1. Erläutern Sie die Extremszenarien im Kontinuum von ALM-Designs.
2. Erläutern Sie die Begriffe der faktoriellen und parametrischen ALM-Designs.
3. Nennen Sie Beispiele für faktorielle, parametrische und faktoriell-parametrische ALM-Designs.
4. Erläutern Sie das Anwendungsszenario eines Einstichproben-T-Tests.
5. Erläutern Sie mögliche Hypothesenszenarien eines Einstichproben-T-Tests.
6. Geben Sie die Definition des Einstichproben-T-Test-Modells wieder.
7. Geben Sie das Theorem zur Parameterschätzung im Einstichproben-T-Test-Modell wieder.
8. Geben Sie das Theorem zur T-Teststatistik des Einstichproben-T-Tests wieder.
9. Geben Sie die Definition des zweiseitigen Einstichproben-T-Tests (mit ungerichteter Hypothese) wieder.
10. Skizzieren Sie die Testgütefunktion des zweiseitigen Einstichproben-T-Tests.
11. Geben Sie das Theorem zur Testumfangkontrolle im zweiseitigen Level- $\alpha_0$ -Einstichproben-T-Test wieder.
12. Erläutern Sie das praktische Vorgehen bei Durchführung eines zweiseitigen Level- $\alpha_0$ -Einstichproben-T-Tests.
13. Geben Sie die Definition des p-Wertes Werts für einen zweiseitigen Einstichproben-T-Test wieder.
14. Von welchen Werten hängt die Powerfunktion eines zweiseitigen Einstichproben-T-Tests ab?
15. Skizzieren Sie die Powerfunktion des Einstichproben-T-Tests bei fester Stichprobengröße.
16. Skizzieren Sie die Powerfunktion des Einstichproben-T-Tests bei festem Nichtzentralitätsparameter.