



# Allgemeines Lineares Modell

BSc Psychologie SoSe 2023

Prof. Dr. Dirk Ostwald

## (14) Kovarianzanalyse

---

Vorbemerkungen

Additive Kovarianzanalyse

Kovarianzanalyse mit Interaktion

---

## **Vorbemerkungen**

Additive Kovarianzanalyse

Kovarianzanalyse mit Interaktion

## Variabilität der Werte einer abhängigen Variable

- Die Werte einer AV unterscheiden sich im Allgemeinen zwischen experimentellen Einheiten.
- Die Schwankungen der Werte einer AV bezeichnet man als *Datenvariabilität*.
- Ziel jeder Datenanalyse ist die Erklärung von Datenvariabilität durch Zerlegung.

## Datenvariabilität und Allgemeines Lineares Modell

- Eine spezielle Art der Quantifizierung von Datenvariabilität ist die Stichprobenvarianz.
- Einen additiven Zugang zur Dekomposition von Datenvariabilität bietet das ALM.
- Den folgenden Überlegungen entspricht datenanalytisch insbesondere die Kovarianzanalyse.

Gesamtvariabilität = Primärvariabilität + Residualvariabilität

### Primärvariabilität

Systematische Veränderung der AV, die allein auf Variation der UV zurückzuführen ist.


Residualvariabilität = Sekundärvariabilität + Zufallsfehler

### Sekundärvariabilität

Systematische Veränderung der AV, die auf die Wirkung von unkontrollierten Störvariablen, nicht aber auf die Variation der UV, zurückzuführen ist.

### Zufallsfehler

Unsystematische Veränderung der AV, die weder auf die Variation der UV, noch auf den Einfluss von Störvariablen zurückzuführen ist.



## Parametrische und faktorielle ALM Designs

### 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 Regressor-Daten Kovarianzen.
- Es besteht ein enger Bezug zur Theorie der Korrelation.
- $\Rightarrow$  Einfache lineare Regression, Multiple lineare Regression

### Faktorielle ALM Designs

- Designmatrizen mit 1en und 0en, manchmal  $-1$ en.
- Betaparameter repräsentieren Gruppenerwartungswerte.
- Betaparameterschätzer repräsentieren Gruppenstichprobenmittel.
- $\Rightarrow$  T-Tests, Einfaktorielle Varianzanalyse, Mehrfaktorielle Varianzanalyse

### Parametrisch-faktorielle ALM Designs

- Designmatrizen mit mehreren parametrischen und faktoriellen Werten.
- $\Rightarrow$  Kovarianzanalyse  $\Leftrightarrow$  Das Allgemeine Lineare Modell

Wir hier betrachten nur exemplarisch den Fall 1 Faktor + 1 Parametrischer Regressor

---

Vorbemerkungen

**Additive Kovarianzanalyse**

Kovarianzanalyse mit Interaktion

# Additive Kovarianzanalyse

## Modell der additiven einfaktoriellen Kovarianzanalyse

Im Modell der additiven einfaktoriellen Kovarianzanalyse möchte man die Erwartungswertparameter  $\mu_{ij}$  der insgesamt  $n = \sum_{i=1}^I n_i$  Datenvariablen

$$v_{ij} \sim N(\mu_{ij}, \sigma^2 I_n) \quad (1)$$

basierend auf den Levels  $i = 1, \dots, I$  des experimentellen Faktors und den entsprechenden Werten  $x_{ij}$  für  $j = 1, \dots, n_i$  der Kovariate modellieren.

Dazu wählt man für jeden Erwartungswertparameter  $\mu_{ij}$  zunächst einen Parameter  $\mu_0$ , der einen Datenvariablen-unspezifischen Offset modelliert. Weiterhin wählt man einen Parameter  $\alpha_i$ , der den Beitrag des  $i$ ten Levels des experimentellen Faktors modelliert und schließlich einen Wichtungparameter  $\beta_0$ , der den Beitrag der Kovariatenwerten  $x_{ij}$  zu  $\mu_{ij}$  quantifiziert.

Das Modell für den Erwartungswertparameter von  $v_{ij}$  für  $i = 1, \dots, I, j = 1, \dots, n_i$  nimmt im Fall der additiven einfaktoriellen Kovarianzanalyse also folgende Form an:

$$\mu_{ij} := \mu_0 + \alpha_i + \beta_0 x_{ij} \text{ mit } \alpha_1 := 0, \quad (2)$$

wobei  $\alpha_1 := 0$  wie im Falle der einfaktoriellen Varianzanalyse eine Überparameterisierung des Modells verhindert.

Man beachte, dass die Form des  $i$ ten Erwartungswertparameters damit eine einfache lineare Regression für jedes Level  $i = 1, \dots, I$  des experimentellen Faktors definiert, bei der  $\mu_0 + \alpha_i$  als Faktorlevel-spezifische Offsetparameter interpretiert werden können und der Steigungsparameter  $\beta_0$  für alle Faktorlevel identisch ist.

## Definition (Modell der additiven einfaktoriellen Kovarianzanalyse)

$v_{ij}$  mit  $i = 1, \dots, I$ ,  $j = 1, \dots, n_i$  sei die Zufallsvariable, die den zum  $i$ ten Level des Faktors gehörenden  $j$ ten Datenpunkt modelliert und  $x_{ij}$  sei der entsprechende Wert Kovariate. Dann hat das *Modell der einfaktoriellen Kovarianzanalyse mit Interaktion* die strukturelle Form

$$v_{ij} = \mu_{ij} + \varepsilon_{ij} \text{ mit } \varepsilon_{ij} \sim N(0, \sigma^2) \text{ u.i.v. für } i = 1, \dots, I, j = 1, \dots, n_i, \sigma^2 > 0 \quad (3)$$

und die Datenverteilungsform

$$v_{ij} \sim N(\mu_{ij}, \sigma^2) \text{ u.v. für } i = 1, \dots, I, j = 1, \dots, n_i, \quad (4)$$

wobei

$$\mu_{ij} := \mu_0 + \alpha_i + \beta_0 x_{ij} \text{ mit } \alpha_1 := 0. \quad (5)$$

### Bemerkungen

- Die Form des  $ij$ ten Erwartungswertparameters

$$\mu_{ij} := \mu_0 + \alpha_i + \beta_0 x_{ij} \text{ mit } \alpha_1 := 0. \quad (6)$$

definiert eine einfache lineare Regression für jedes  $i = 1, \dots, I$ , wobei

- $\mu_0 + \alpha_i$  ein Faktorlevel-spezifischer Offsetparameter ist und
- der Steigungsparameter  $\beta_0$  für alle Faktorlevel identisch ist.

## Theorem (Designmatrixform der $2 \times n$ additiven einfaktoriellen Kovarianzanalyse)

Gegeben sei die strukturelle Form eines additiven einfaktoriellen Kovarianzanalysemodells mit  $I := 2$  und es sei  $n := n_1 + n_2$  die Gesamtzahl an Datenvariablen. Dann hat dieses Modell die Designmatrixform

$$v \sim N(X\beta, \sigma^2 I_n) \quad (7)$$

mit

$$v := \begin{pmatrix} v_{11} \\ \vdots \\ v_{1n_1} \\ v_{21} \\ \vdots \\ v_{2n_2} \end{pmatrix}, \quad X := \begin{pmatrix} 1 & 0 & x_{11} \\ \vdots & \vdots & \vdots \\ 1 & 0 & x_{1n_1} \\ 1 & 1 & x_{21} \\ \vdots & \vdots & \vdots \\ 1 & 1 & x_{2n_2} \end{pmatrix} \in \mathbb{R}^{n \times 3}, \quad \beta := \begin{pmatrix} \mu_0 \\ \alpha_2 \\ \beta_0 \end{pmatrix} \in \mathbb{R}^3 \text{ und } \sigma^2 > 0. \quad (8)$$

Bemerkungen

- Das Theorem ergibt sich direkt mit den Regeln der Matrixmultiplikation.

## Anwendungsbeispiel

Experimenteller Faktor/Studiengruppe ( $I := 2, i = 1, 2$ )

- Face-to-face vs. Online Psychotherapie

Parametrischer Regressor/Kovariate ( $x_{ij}$ )

- Dauer der Depressionssymptomatik zu Beginn der Intervention



Abhängige Variable/Primäres Ergebnismaß ( $v_{ij}$ )

- Pre-Post-BDI-Differenzwerte

## Beispieldatensatz

	Therapie	Dauer	dBDI
1	F2F	3.7	6
2	F2F	5.4	6
3	F2F	3.3	7
4	F2F	8.2	7
5	F2F	5.7	4
6	F2F	3.4	8
7	F2F	6.0	2
8	F2F	6.5	3
9	F2F	6.2	8
10	F2F	4.4	8
17	ONL	5.0	12
18	ONL	6.9	9
19	ONL	6.6	7
20	ONL	6.2	7
21	ONL	6.8	9
22	ONL	6.6	10
23	ONL	5.1	9
24	ONL	1.0	14
25	ONL	6.2	10
26	ONL	4.9	12

## Visualisierung



## Modellformulierung

### Modell 1 | Keine Berücksichtigung der Kovariate

$$v_{ij} \sim N(\mu_{ij}, \sigma^2) \text{ mit } \mu_{ij} := \mu_0 + \alpha_i \text{ und } \alpha_1 := 0 \text{ und } \sigma^2 > 0$$

$$\Leftrightarrow v \sim N(X\beta, \sigma^2 I_n) \text{ mit } X := \begin{pmatrix} 1 & 0 \\ \vdots & \vdots \\ 1 & 0 \\ 1 & 1 \\ \vdots & \vdots \\ 1 & 1 \end{pmatrix}, \beta := \begin{pmatrix} \mu_0 \\ \alpha_2 \end{pmatrix} \text{ und } \sigma^2 > 0 \quad (9)$$

### Modell 2 | Additive Berücksichtigung der Kovariate

$$v_{ij} \sim N(\mu_{ij}, \sigma^2) \text{ mit } \mu_{ij} := \mu_0 + \alpha_i + \beta_0 x_{ij} \text{ und } \alpha_1 := 0 \text{ und } \sigma^2 > 0$$

$$\Leftrightarrow v \sim N(X\beta, \sigma^2 I_n) \text{ mit } X := \begin{pmatrix} 1 & 0 & x_{11} \\ \vdots & \vdots & \vdots \\ 1 & 0 & x_{1n_1} \\ 1 & 1 & x_{21} \\ \vdots & \vdots & \vdots \\ 1 & 1 & x_{2n_2} \end{pmatrix}, \beta := \begin{pmatrix} \mu_0 \\ \alpha_2 \\ \beta_0 \end{pmatrix} \text{ und } \sigma^2 > 0 \quad (10)$$

# Additive Kovarianzanalyse

## Implementation

```
fname = file.path(getwd(), "./14_Daten/14_Kovarianzanalyse-1.csv") # Datensatzdateiname
D = read.table(fname, sep = ",", header = TRUE) # Datensatz
n_i = c(sum(D$Therapie == "F2F"), sum(D$Therapie == "ONL")) # Anzahl Datenpunkte pro Gruppe
y = D$dbDI # Daten
n = length(y) # Gesamtanzahldatenpunkte
XS = list() # Modell 1 und 2 Liste
CS = list() # Kontrastgewichtsvektorenliste
XS[[1]] = matrix(c(rep(1,n_i[1]),rep(1,n_i[2]), # \mu_0 Regressor
                  rep(0,n_i[1]),rep(1,n_i[2])), nrow = n) # \alpha_2 Regressor
XS[[2]] = matrix(c(rep(1,n_i[1]),rep(1,n_i[2]), # \mu_0 Regressor
                  rep(0,n_i[1]),rep(1,n_i[2]), # \alpha_2 Regressor
                  D$Dauer),nrow = n) # x Regressor
CS[[1]] = matrix(c(0,1) , nrow = 2) # Kontrastgewichtsvektor \alpha_2
CS[[2]] = matrix(c(0,1,0), nrow = 3) # Kontrastgewichtsvektor \alpha_2
B = list() # Betaparameterschätzerliste
S = rep(NA,n) # Varianzparameterschätzervektor
T = rep(NA,2) # T-Statistikvektor
for(i in 1:2){ # Modell 1 und 2 Iterationen
  X = XS[[i]] # Designmatrix
  p = ncol(X) # Anzahl Betaparameter
  beta_hat = solve(t(X) %*% X) %*% t(X) %*% y # Betaparameterschätzer vollständiges Modell
  eps_hat = y - X %*% beta_hat # Residuenvektor
  sigsq_hat = (t(eps_hat) %*% eps_hat)/(n-p) # Varianzparameterschätzer
  c = CS[[i]] # Kontrastgewichtsvektor
  t_num = t(c) %*% beta_hat # Zähler der Zweistichproben-T-Teststatistik
  t_den = sqrt(sigsq_hat %*% t(c) %*% solve(t(X) %*% X) %*% c) # Nenner der Zweistichproben-T-Teststatistik
  t = t_num/t_den # Wert der Zweistichproben-T-Teststatistik
  B[[i]] = beta_hat # Betaparameterschätzer
  S[i] = sigsq_hat # Varianzparameterschätzer
  T[i] = t # T-Statistik
}
```

## Ergebnisse

Modell 1   Betaparameterschätzer	:	5.56	4.12	
Modell 2   Betaparameterschätzer	:	10.05	4.2	-0.86
Modell 1   Varianzparameterschätzer	:	5.65		
Modell 2   Varianzparameterschätzer	:	3.14		
Modell 1   T-Statistik ONL Therapie	:	4.91		
Modell 2   T-Statistik ONL Therapie	:	6.7		

In Modell 2 ist der Varianzparameterschätzer kleiner als in Modell 1.

⇒ Der parametrische Regressor erklärt Datenvarianz.

Die Betaparameterschätzer für den ONL Therapieeffekt sind in Modell 1 und Modell 2 ähnlich.



⇒ Das Signal-zu-Rauschen Verhältnis (T-Statistik) für den ONL Therapieeffekt ist Modell 2 höher.

Prinzipiell kann man die beobachteten Daten für den geschätzten Dauer Effekt durch

$$\hat{v}_{ij}^{\text{adj}} = v_{ij} - \hat{\beta}_0 x_{ij} \quad (11)$$

“korrigieren” und erhält so einen “adjustierten Datensatz”.

# Additive Kovarianzanalyse



---

Vorbemerkungen

Additive Kovarianzanalyse

**Kovarianzanalyse mit Interaktion**

# Kovarianzanalyse mit Interaktion

## Modell der einfaktoriellen Kovarianzanalyse mit Interaktion

Wie im Modell der additiven einfaktoriellen Kovarianzanalyse möchte man im Modell der einfaktoriellen Kovarianzanalyse mit Interaktion die Erwartungswertparameter  $\mu_{ij}$  der insgesamt  $n = \sum_{i=1}^I n_i$  Datenvariablen

$$v_{ij} \sim N(\mu_{ij}, \sigma^2 I_n) \quad (12)$$

basierend auf den Leveln  $i = 1, \dots, I$  des experimentellen Faktors und den entsprechenden Werten  $x_{ij}$  für  $j = 1, \dots, n_i$  der Kovariate modellieren. Über das Szenario der additiven einfaktoriellen Kovarianzanalyse hinaus möchte man dabei explizit einen Faktorlevel-spezifischen Einfluss der Kovariate auf die Erwartungswertparameter zulassen.

Dazu wählt man für jeden Erwartungswertparameter  $\mu_{ij}$  zunächst wieder einen Parameter  $\mu_0$ , der einen Datenvariablen-unspezifischen Offset modelliert. Weiterhin wählt man einen Parameter  $\alpha_i$ , der den Beitrag des  $i$ ten Levels des experimentellen Faktors modelliert. Den Wichtungsparameter des Beitrags der Kovariaten  $x_{ij}$  zu  $\mu_{ij}$  modelliert man nun hier mithilfe eines Faktorlevel-unspezifischen Parameter  $\beta_0$  und eines Faktorlevel-spezifischen Parameters  $\gamma_i$  für  $i = 1, \dots, I$ . Das Modell für den Erwartungswertparameter von  $v_{ij}$  für  $i = 1, \dots, I, j = 1, \dots, n_i$  nimmt im Fall der einfaktoriellen Kovarianzanalyse mit Interaktion damit folgende Form an:

$$\mu_{ij} := \mu_0 + \alpha_i + (\beta_0 + \gamma_i)x_{ij} \text{ mit } \alpha_1 := \gamma_1 := 0, \quad (13)$$

wobei  $\alpha_1 := \gamma_1 := 0$  wie im Fall der zweifaktoriellen Varianzanalyse mit Interaktion eine Überparameterisierung des Modells verhindert.

Man beachte, dass die Form des  $ij$ ten Erwartungswertparameters damit eine einfache lineare Regression für jedes Level  $i = 1, \dots, I$  des experimentellen Faktors definiert, bei der  $\mu_0 + \alpha_i$  als Faktorlevel-spezifische Offsetparameter interpretiert werden können und sich die Steigungsparameter  $\beta_0 + \gamma_i$  über die Faktorlevel unterscheiden können. Es werden also Unterschiede (zwischen den Faktorleveln) von Unterschieden (zwischen den Erwartungswertparametern eines Faktorlevels in Abhängigkeit vom Wert der Kovariate), also Interaktionen, mit modelliert.

## Definition (Modell der einfaktoriellen Kovarianzanalyse mit Interaktion)

$v_{ij}$  mit  $i = 1, \dots, I$ ,  $j = 1, \dots, n_i$  sei die Zufallsvariable, die den zum  $i$ ten Level des Faktors gehörenden  $j$ ten Datenpunkt modelliert und  $x_{ij}$  sei der entsprechende Wert Kovariate. Dann hat das *Modell einfaktoriellen Kovarianzanalyse mit Interaktion* die strukturelle Form

$$v_{ij} = \mu_{ij} + \varepsilon_{ij} \text{ mit } \varepsilon_{ij} \sim N(0, \sigma^2) \text{ u.i.v. für } i = 1, \dots, I, j = 1, \dots, n_i, \sigma^2 > 0 \quad (14)$$

und die Datenverteilungsform

$$v_{ij} \sim N(\mu_{ij}, \sigma^2) \text{ u.v. für } i = 1, \dots, I, j = 1, \dots, n_i, \quad (15)$$

wobei

$$\mu_{ij} := \mu_0 + \alpha_i + (\beta_0 + \gamma_i)x_{ij} \text{ mit } \alpha_1 := \gamma_1 := 0. \quad (16)$$

### Bemerkungen

- Die Form des  $ij$ ten Erwartungswertparameters

$$\mu_{ij} := \mu_0 + \alpha_i + (\beta_0 + \gamma_i)x_{ij} \text{ mit } \alpha_1 := \gamma_1 := 0. \quad (17)$$

definiert eine einfache lineare Regression für jedes  $i = 1, \dots, I$ , wobei

- $\mu_0$  und  $\alpha_i$  Faktorlevel-unspezifische und -spezifische Offsetparameter sind und,
- $\beta_0$  und  $\gamma_i$  Faktorlevel-unspezifische und -spezifische Steigungsparameter sind.

## Theorem (Designmatrixform der $2 \times n$ einfaktoriellen Kovarianzanalyse mit Interaktion)

Gegeben sei die strukturelle Form eines einfaktoriellen Kovarianzanalysemodells mit Interaktion mit  $I := 2$  und es sei  $n := n_1 + n_2$  die Gesamtanzahl an Datenvariablen. Dann hat dieses Modell die Designmatrixform

$$v \sim N(X\beta, \sigma^2 I_n) \quad (18)$$

mit

$$v := \begin{pmatrix} v_{11} \\ \vdots \\ v_{1n_1} \\ v_{21} \\ \vdots \\ v_{2n_2} \end{pmatrix}, \quad X := \begin{pmatrix} 1 & 0 & x_{11} & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & x_{1n_1} & 0 \\ 1 & 1 & x_{21} & x_{21} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 1 & x_{2n_2} & x_{2n_2} \end{pmatrix} \in \mathbb{R}^{n \times 4}, \quad \beta := \begin{pmatrix} \mu_0 \\ \alpha_2 \\ \beta_0 \\ \gamma_2 \end{pmatrix} \in \mathbb{R}^4 \text{ und } \sigma^2 > 0. \quad (19)$$

### Bemerkungen

- Das Theorem folgt aus der Definition der strukturellen Form für  $I := 2$

$$\mu_{1j} := \mu_0 + \alpha_1 + \beta_0 x_{1j} + \gamma_1 x_{1j} \quad (20)$$

$$\mu_{2j} := \mu_0 + \alpha_2 + \beta_0 x_{2j} + \gamma_2 x_{2j}$$

für  $\alpha_1 := \gamma_1 := 0$  direkt aus den Regeln der Matrixmultiplikation.

## Anwendungsbeispiel

Experimenteller Faktor/Studiengruppe ( $I := 2, i = 1, 2$ )

- Face-to-face vs. Online Psychotherapie

Parametrischer Regressor/Kovariate ( $x_{ij}$ )

- Digitalaffinität



Abhängige Variable/Primäres Ergebnismaß ( $v_{ij}$ )

- Pre-Post-BDI-Differenzwerte

## Beispieldatensatz

	Therapie	Dig.Affin	dBDI
1	F2F	3.7	5
2	F2F	5.4	6
3	F2F	3.3	5
4	F2F	8.2	10
5	F2F	5.7	5
6	F2F	3.4	6
7	F2F	6.0	3
8	F2F	6.5	4
9	F2F	6.2	9
10	F2F	4.4	8
17	ONL	5.0	9
18	ONL	6.9	10
19	ONL	6.6	7
20	ONL	6.2	7
21	ONL	6.8	10
22	ONL	6.6	10
23	ONL	5.1	7
24	ONL	1.0	3
25	ONL	6.2	10
26	ONL	4.9	9

# Kovarianzanalyse mit Interaktion



## Modellformulierung

### Modell 1 | Additive Berücksichtigung der Kovariate

$v_{ij} \sim N(\mu_{ij}, \sigma^2)$  mit  $\mu_{ij} := \mu_0 + \alpha_i + \beta_0 x_{ij}$  und  $\alpha_1 := 0$  und  $\sigma^2 > 0$

$$\Leftrightarrow v \sim N(X\beta, \sigma^2 I_n) \text{ mit } X := \begin{pmatrix} 1 & 0 & x_{11} \\ \vdots & \vdots & \vdots \\ 1 & 0 & x_{1n_1} \\ 1 & 1 & x_{21} \\ \vdots & \vdots & \vdots \\ 1 & 1 & x_{2n_2} \end{pmatrix}, \beta := \begin{pmatrix} \mu_0 \\ \alpha_2 \\ \beta_0 \end{pmatrix} \text{ und } \sigma^2 > 0 \quad (21)$$

### Modell 2 | Additive und interaktive Berücksichtigung der Kovariate

$v_{ij} \sim N(\mu_{ij}, \sigma^2)$  mit  $\mu_{ij} := \mu_0 + \alpha_i + (\beta_0 + \gamma_i)x_{ij}$  und  $\alpha_1 := \gamma_1 := 0$  und  $\sigma^2 > 0$

$$\Leftrightarrow v \sim N(X\beta, \sigma^2 I_n) \text{ mit } X := \begin{pmatrix} 1 & 0 & x_{11} & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & x_{1n_1} & 0 \\ 1 & 1 & x_{21} & x_{21} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 1 & x_{2n_2} & x_{2n_2} \end{pmatrix}, \beta := \begin{pmatrix} \mu_0 \\ \alpha_2 \\ \beta_0 \\ \gamma_2 \end{pmatrix} \text{ und } \sigma^2 > 0 \quad (22)$$

# Kovarianzanalyse mit Interaktion

## Implementation

```
> Run Cell | Run Next Cell | Run Above
979 ***{r}
980 fname = file.path("../14_Daten/14_Kovarianzanalyse-2.csv") # Datensatzdateiname
981 D = read.table(fname, sep = ",", header = TRUE) # Datensatz
982 n_i = c(sum(D$Therapie == "F2F"), sum(D$Therapie == "ONL")) # Anzahl Datenpunkte pro Gruppe
983 y = D$dBDI # Daten
984 n = length(y) # Gesamtanzahl Datenpunkte
985 XS = list() # Model 1 und 2 Liste
986 CS = list() # Kontrastgewichtsvektorenliste
987 XS[[1]] = matrix(c(rep(1,n_i[1]), rep(1,n_i[2]), # \mu_0 Regressor
988 rep(0,n_i[1]), rep(1,n_i[2]), # \alpha_2 Regressor
989 D$Dig.Affin, nrow = n) # \beta_2 Regressor
990 XS[[2]] = matrix(c(rep(1,n_i[1]), rep(1,n_i[2]), # \mu_0 Regressor
991 rep(0,n_i[1]), rep(1,n_i[2]), # \alpha_2 Regressor
992 D$Dig.Affin, # \beta_2 Regressor
993 D$Dig.Affin*(c(rep(0,n_i[1]),rep(1,n_i[2]))), # \gamma_2 Regressor
994 nrow = n) # Zellenanzahl
995 CS[[1]] = matrix(c(0,1,0), nrow = 3) # Kontrastgewichtsvektor \alpha_2
996 CS[[2]] = matrix(c(0,1,0,0), nrow = 4) # Kontrastgewichtsvektor \alpha_2
997 B = list() # Betaparameterschätzerliste
998 S = rep(NA,2) # Varianzparameterschätzervektor
999 T = rep(NA,2) # T-Statistikvektor
1000 for(i in 1:2){ # Modell 1 und 2 Iterationen
1001 X = XS[[i]] # Designmatrix
1002 p = ncol(X) # Anzahl Betaparameter
1003 beta_hat = solve(t(X) %*% X) %*% t(X) %*% y # Betaparameterschätzer vollständiges Modell
1004 eps_hat = y - X %*% beta_hat # Residuenvektor
1005 sigsqn_hat = (t(eps_hat) %*% eps_hat)/(n-p) # Varianzparameterschätzer
1006 c = CS[[i]] # Kontrastgewichtsvektor
1007 t_num = t(c) %*% beta_hat # Zähler der Zweistichproben-T-Teststatistik
1008 t_den = sqrt(sigsqn_hat %*% t(c) %*% solve(t(X) %*% X) %*% c) # Nenner der Zweistichproben-T-Teststatistik
1009 t = t_num/t_den # Wert der Zweistichproben-T-Teststatistik
1010 B[[i]] = beta_hat # Betaparameterschätzer
1011 S[i] = sigsqn_hat # Varianzparameterschätzer
1012 T[i] = t # T-Statistik
1013 }
1014 ***
```

## Ergebnisse

Modell 1   Betaparameterschätzer	:	2.73	1.7	0.58	
Modell 2   Betaparameterschätzer	:	5.03	-3.47	0.14	0.99
Modell 1   Varianzparameterschätzer:		3.92			
Modell 2   Varianzparameterschätzer:		3.15			
Modell 1   T-Statistik ONL Therapie:		2.43			
Modell 2   T-Statistik ONL Therapie:		-1.79			



In Modell 1 wird der ONL Therapieeffekt positiv, in Modell 2 negativ geschätzt.

Entsprechend ist die T-Statistik für ONL Therapie in Modell 1 positiv, in Modell 2 negativ.

Der wahre, aber unbekannte, Betaparameterwert ist  $\beta := (5, -3, 0, 1)^T$

- ⇒ Die Abhängigkeit von Digitalaffinität kommt in der ONL Therapie zum Tragen, in F2F nicht.
- ⇒ Der Haupteffekt der Therapieart ist schwierig zu beurteilen.
- ⇒ ONL Therapie ist bei niedriger Digitalaffinität nicht so wirksam wie F2F Therapie.
- ⇒ ONL Therapie ist bei hoher Digitalaffinität so wirksam wie F2F.

# Kovarianzanalyse mit Interaktion



---

Vorbemerkungen

Additive Kovarianzanalyse

Kovarianzanalyse mit Interaktion