



# Allgemeines Lineares Modell

BSc Psychologie, SoSe 2024

Joram Soch

## (14) Kovarianzanalyse

---

Vorbemerkungen

Additive Kovarianzanalyse

Kovarianzanalyse mit Interaktion

Selbstkontrollfragen

---

## **Vorbemerkungen**

Additive Kovarianzanalyse

Kovarianzanalyse mit Interaktion

Selbstkontrollfragen

## 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 liegt datenanalytisch die Kovarianzanalyse zugrunde.

Gesamtvariabilität = Primärvariabilität + Residualvariabilität

Primärvariabilität

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

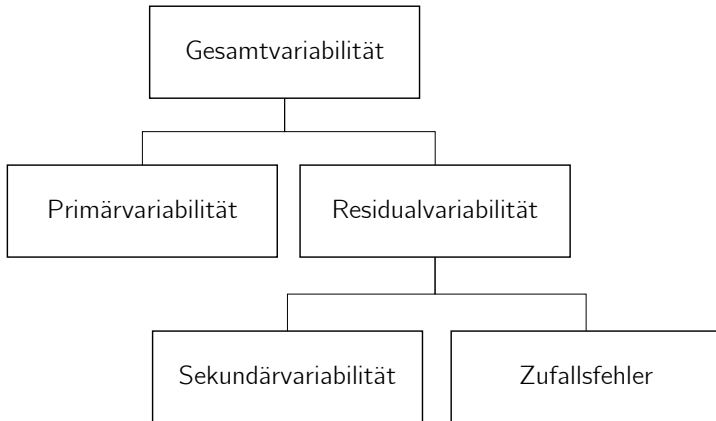
Residualvariabilität = Sekundärvariabilität + Zufallsfehler

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 besitzen Spalten mit 1en und 0en.
- Betaparameter repräsentieren Gruppenerwartungswerte.
- Betaparameterschätzer ergeben sich aus Gruppenstichprobenmitteln.
- $\Rightarrow$  T-Tests, einfaktorielle Varianzanalyse, mehrfaktorielle Varianzanalyse

### Parametrisch-faktorielle ALM-Designs

- Designmatrizen mit mehreren parametrischen und faktoriellen Regressoren.
- $\Rightarrow$  Kovarianzanalyse  $\Leftrightarrow$  Allgemeines Lineares Modell

Wir betrachten hier exemplarisch den Fall 1 Faktor + 1 parametrischer Regressor.



---

Vorbemerkungen

## **Additive Kovarianzanalyse**

Kovarianzanalyse mit Interaktion

Selbstkontrollfragen

# 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

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

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.

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 Gewichtungparameter  $\beta_0$ , der den Beitrag der Kovariatenwerten  $x_{ij}$  zu  $\mu_{ij}$  quantifiziert.

Das Modell für den Erwartungswertparameter von  $y_{ij}$  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, wobei  $\mu_0 + \alpha_i$  als Faktorlevel-spezifische Offsetparameter interpretiert werden können und der Steigungsparameter  $\beta_0$  für alle Faktorlevel identisch ist.

## Definition (Modell der additiven einfaktoriellen Kovarianzanalyse)

$y_{ij}$  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 der Kovariate. Dann hat das *Modell der additiven einfaktoriellen Kovarianzanalyse* die strukturelle Form

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

und die Datenverteilungsform

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

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 additiven einfaktoriellen Kovarianzanalyse)

Gegeben sei die strukturelle Form eines additiven einfaktoriellen Kovarianzanalysemodells mit Anzahl der Faktorlevel  $I$  und es sei  $n := \sum_{i=1}^I n_i$  die Gesamtzahl an Datenvariablen. Dann hat dieses Modell die Designmatrixform

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

mit

$$y := \begin{pmatrix} y_{11} \\ \vdots \\ y_{1n_1} \\ y_{21} \\ \vdots \\ y_{2n_2} \\ \vdots \\ y_{I1} \\ \vdots \\ y_{In_I} \end{pmatrix}, \quad X := \begin{pmatrix} 1 & 0 & & 0 & x_{11} \\ \vdots & \vdots & \dots & \vdots & \vdots \\ 1 & 0 & & 0 & x_{1n_1} \\ 1 & 1 & & 0 & x_{21} \\ \vdots & \vdots & \dots & \vdots & \vdots \\ 1 & 1 & & 0 & x_{2n_2} \\ \vdots & \vdots & \dots & \vdots & \vdots \\ 1 & 0 & & 1 & x_{I1} \\ \vdots & \vdots & \dots & \vdots & \vdots \\ 1 & 0 & & 1 & x_{In_I} \end{pmatrix} \in \mathbb{R}^{n \times (I+1)}, \quad \beta := \begin{pmatrix} \mu_0 \\ \alpha_2 \\ \vdots \\ \alpha_I \\ \beta_0 \end{pmatrix} \in \mathbb{R}^{I+1} \text{ und } \sigma^2 > 0. \quad (8)$$

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 ( $x_{ij}, j = 1, \dots, n_i$ )

- Dauer der Depressionssymptomatik zu Beginn der Intervention



abhängige Variable/primäres Ergebnismaß ( $y_{ij}, j = 1, \dots, n_i$ )

- BDI Pre-Post-Differenzwerte

Beispieldatensatz ( $n = 32$ ,  $n_i = 16$  für  $i = 1, 2$ ; hier:  $i = 1, 2$ ,  $j = 1, \dots, 10$ )

	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

$$y_{ij} \sim N(\mu_{ij}, \sigma^2) \text{ mit } \mu_{ij} := \mu_0 + \alpha_i \text{ und } \alpha_1 := 0 \text{ und } \sigma^2 > 0 \quad (9)$$

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

### Modell 2 | Additive Berücksichtigung der Kovariate

$$y_{ij} \sim N(\mu_{ij}, \sigma^2) \text{ mit } \mu_{ij} := \mu_0 + \alpha_i + \beta_0 x_{ij} \text{ und } \alpha_1 := 0 \text{ und } \sigma^2 > 0 \quad (11)$$

$$\Leftrightarrow y \sim N(X\beta, \sigma^2 I_n) \text{ mit } X := \begin{pmatrix} 1 & 0 & x_{11} \\ \vdots & \vdots & \vdots \\ 1 & 0 & x_{1n_1} \\ 1 & 1 & x_{21} \\ \vdots & \vdots & \vdots \\ 1 & 1 & x_{2n_2} \end{pmatrix}, \beta := \begin{pmatrix} \mu_0 \\ \alpha_2 \\ \beta_0 \end{pmatrix} \text{ und } \sigma^2 > 0 \quad (12)$$



# Additive Kovarianzanalyse

## Implementation

```
fname = file.path(getwd(), "Daten", "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,n) # T-Statistik-Vektor
for(i in 1:2){ # Iteration über Modelle
  X = XS[[i]] # Designmatrix
  p = ncol(X) # Anzahl Betaparameter
  beta_hat = solve(t(X) %*% X) %*% t(X) %*% y # Betaparameterschätzer
  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 : 10.1 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.



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

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

$$\hat{y}_{ij}^{\text{adj}} = y_{ij} - \hat{\beta}_0 x_{ij} \quad (13)$$

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

## Visualisierung



---

Vorbemerkungen

Additive Kovarianzanalyse

**Kovarianzanalyse mit Interaktion**

Selbstkontrollfragen

# 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

$$y_{ij} \sim N(\mu_{ij}, \sigma^2 I_n) \quad (14)$$

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  $y_{ij}$  für  $i = 1, \dots, I, j = 1, \dots, n_i$  nimmt im Fall der einfaktoriellen Kovarianzanalyse mit Interaktion damit folgende Form an:

$$\mu_{ij} := \mu_0 + \alpha_i + (\beta_0 + \gamma_i)x_{ij} \text{ mit } \alpha_1 := \gamma_1 := 0, \quad (15)$$

wobei  $\alpha_1 := \gamma_1 := 0$  wie im Fall der zweiaktoriellen Varianzanalyse mit Interaktion 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  $\mu_0 + \alpha_i$  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), d.h. Interaktionen, mit modelliert.

## Definition (Modell der einfaktoriellen Kovarianzanalyse mit Interaktion)

$y_{ij}$  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 der Kovariate. Dann hat das *Modell einfaktoriellen Kovarianzanalyse mit Interaktion* die strukturelle Form

$$y_{ij} = \mu_{ij} + \varepsilon_{ij} \text{ mit } \varepsilon_{ij} \sim N(0, \sigma^2) \text{ u.i.v. für } i = 1, \dots, I, j = 1, \dots, n_i, \sigma^2 > 0 \quad (16)$$

und die Datenverteilungsform

$$y_{ij} \sim N(\mu_{ij}, \sigma^2) \text{ u.v. für } i = 1, \dots, I, j = 1, \dots, n_i, \quad (17)$$

wobei

$$\mu_{ij} := \mu_0 + \alpha_i + (\beta_0 + \gamma_i)x_{ij} \text{ mit } \alpha_1 := \gamma_1 := 0. \quad (18)$$

### Bemerkungen

- Die Form des  $ij$ ten Erwartungswertparameters

$$\mu_{ij} := \mu_0 + \alpha_i + (\beta_0 + \gamma_i)x_{ij} \text{ mit } \alpha_1 := \gamma_1 := 0 \quad (19)$$

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 einfaktoriellen Kovarianzanalyse mit Interaktion)

Gegeben sei die strukturelle Form eines einfaktoriellen Kovarianzanalysemodells mit Interaktion mit Anzahl der Faktorebene  $I$  und es sei  $n := \sum_{i=1}^I n_i$  die Gesamtanzahl an Datenvariablen. Dann hat dieses Modell die Designmatrixform

$$y \sim N(X\beta, \sigma^2 I_n) \quad (20)$$

mit

$$y := \begin{pmatrix} y_{11} \\ \vdots \\ y_{1n_1} \\ y_{21} \\ \vdots \\ y_{2n_2} \\ \vdots \\ y_{I1} \\ \vdots \\ y_{In_I} \end{pmatrix}, \quad X := \begin{pmatrix} 1 & 0 & & 0 & x_{11} & 0 & & 0 \\ \vdots & \vdots & \dots & \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & 0 & & 0 & x_{1n_1} & 0 & & 0 \\ 1 & 1 & & 0 & x_{21} & x_{21} & & 0 \\ \vdots & \vdots & \dots & \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & 1 & & 0 & x_{2n_2} & x_{2n_2} & & 0 \\ \vdots & \vdots & & \dots & \vdots & \vdots & & \dots \\ 1 & 0 & & 1 & x_{I1} & 0 & & x_{I1} \\ \vdots & \vdots & \dots & \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & 0 & & 1 & x_{In_I} & 0 & & x_{In_I} \end{pmatrix} \in \mathbb{R}^{n \times (2I)}, \quad \beta := \begin{pmatrix} \mu_0 \\ \alpha_2 \\ \vdots \\ \alpha_I \\ \beta_0 \\ \gamma_2 \\ \vdots \\ \gamma_I \end{pmatrix} \in \mathbb{R}^{2I} \text{ und } \sigma^2 > 0. \quad (21)$$

### 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 ( $x_{ij}, j = 1, \dots, n_i$ )

- Digitalaffinität der Studienteilnehmer

abhängige Variable/primäres Ergebnismaß ( $y_{ij}, j = 1, \dots, n_i$ )

- BDI Pre-Post-Differenzwerte





# Kovarianzanalyse mit Interaktion

Beispieldatensatz ( $n = 32$ ,  $n_i = 16$  für  $i = 1, 2$ ; hier:  $i = 1, 2$ ,  $j = 1, \dots, 10$ )

	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

## Visualisierung



# Kovarianzanalyse mit Interaktion

## Modellformulierung

### Modell 1 | additive Berücksichtigung der Kovariate

$$y_{ij} \sim N(\mu_{ij}, \sigma^2) \text{ mit } \mu_{ij} := \mu_0 + \alpha_i + \beta_0 x_{ij} \text{ und } \alpha_1 := 0 \text{ und } \sigma^2 > 0 \quad (22)$$

$$\Leftrightarrow \mathbf{y} \sim N(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I}_n) \text{ mit } \mathbf{X} := \begin{pmatrix} 1 & 0 & x_{11} \\ \vdots & \vdots & \vdots \\ 1 & 0 & x_{1n_1} \\ 1 & 1 & x_{21} \\ \vdots & \vdots & \vdots \\ 1 & 1 & x_{2n_2} \end{pmatrix}, \boldsymbol{\beta} := \begin{pmatrix} \mu_0 \\ \alpha_2 \\ \beta_0 \end{pmatrix} \text{ und } \sigma^2 > 0 \quad (23)$$

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

$$y_{ij} \sim N(\mu_{ij}, \sigma^2) \text{ mit } \mu_{ij} := \mu_0 + \alpha_i + (\beta_0 + \gamma_i)x_{ij} \text{ und } \alpha_1 := \gamma_1 := 0 \text{ und } \sigma^2 > 0 \quad (24)$$

$$\Leftrightarrow \mathbf{y} \sim N(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I}_n) \text{ mit } \mathbf{X} := \begin{pmatrix} 1 & 0 & x_{11} & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & x_{1n_1} & 0 \\ 1 & 1 & x_{21} & x_{21} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 1 & x_{2n_2} & x_{2n_2} \end{pmatrix}, \boldsymbol{\beta} := \begin{pmatrix} \mu_0 \\ \alpha_2 \\ \beta_0 \\ \gamma_2 \end{pmatrix} \text{ und } \sigma^2 > 0 \quad (25)$$

# Kovarianzanalyse mit Interaktion

## Implementation

```
1060 fname = file.path("./Daten/Kovarianzanalyse-2.csv") # Datensatzdateiname
1061 D = read.table(fname, sep = ",", header = TRUE) # Datensatz
1062 n_i = c(sum(D$Therapie == "F2F"), sum(D$Therapie == "ONL")) # Anzahl Datenpunkte pro Gruppe
1063 y = D$dBDI # Daten
1064 n = length(y) # Gesamtanzahl Datenpunkte
1065 XS = list() # Model 1 und 2 Liste
1066 CS = list() # Kontrastgewichtsvektorenliste
1067 XS[[1]] = matrix(c(rep(1,n_i[1]), rep(1,n_i[2]), # \mu_0 Regressor
1068 rep(0,n_i[1]), rep(1,n_i[2]), # \alpha_2 Regressor
1069 D$dBDI.Affin, nrow = n) # \beta_2 Regressor
1070 XS[[2]] = matrix(c(rep(1,n_i[1]), rep(1,n_i[2]), # \mu_0 Regressor
1071 rep(0,n_i[1]), rep(1,n_i[2]), # \alpha_2 Regressor
1072 D$dBDI.Affin, # \beta_2 Regressor
1073 D$dBDI.Affin*(c(rep(0,n_i[1]),rep(1,n_i[2]))), # \gamma_2 Regressor
1074 nrow = n) # Anzahl Zeilen der Designmatrix
1075 CS[[1]] = matrix(c(0,1,0), nrow = 3) # Kontrastgewichtsvektor \alpha_2
1076 CS[[2]] = matrix(c(0,1,0,0), nrow = 4) # Kontrastgewichtsvektor \alpha_2
1077 B = list() # Betaparameterschätzerliste
1078 S = rep(NA,n) # Varianzparameterschätzervektor
1079 T = rep(NA,n) # T-Statistik-Vektor
1080 for(i in 1:2){ # Iteration über Modelle
1081 X = XS[[i]] # Designmatrix
1082 p = ncol(X) # Anzahl Betaparameter
1083 beta_hat = solve(t(X) %*% X) %*% t(X) %*% y # Betaparameterschätzer
1084 eps_hat = y - X %*% beta_hat # Residuenvektor
1085 sigsq_hat = (t(eps_hat) %*% eps_hat)/(n-p) # Varianzparameterschätzer
1086 c = CS[[i]] # Kontrastgewichtsvektor
1087 t_num = t(c) %*% beta_hat # Zähler der Zweistichproben-T-Teststatistik
1088 t_den = sqrt(sigsq_hat %*% t(c) %*% solve(t(X) %*% X) %*% c) # Nenner der Zweistichproben-T-Teststatistik
1089 t = t_num/t_den # Wert der Zweistichproben-T-Teststatistik
1090 B[[i]] = beta_hat # Betaparameterschätzer
1091 S[i] = sigsq_hat # Varianzparameterschätzer
1092 T[i] = t # T-Statistik
1093 }
```

## 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.

Die wahren, aber unbekanntenen Betaparameterwerte sind  $\beta := (5, -3, 0, 1)^T$ .

- ⇒ Die Abhängigkeit von Digitalaffinität kommt bei ONL zum Tragen, bei 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 wirksamer als F2F-Therapie.



---

Vorbemerkungen

Additive Kovarianzanalyse

Kovarianzanalyse mit Interaktion

**Selbstkontrollfragen**

# Selbstkontrollfragen

---

1. Erläutern Sie die Begriffe der Gesamt-/Primär-/Sekundär- und Residualvarianz.
2. Geben Sie jeweils zwei Beispiele für parametrische bzw. faktorielle ALM-Designs an.
3. Geben Sie die Definition des Modells der additiven einfaktoriellen Kovarianzanalyse (EKA) wieder.
4. Erläutern Sie die Bedeutung der Parameter  $\mu_0$ ,  $\alpha_i$  und  $\beta_0$  im Modell der additiven EKA.
5. Geben Sie die Designmatrixform des Modells der additiven EKA für  $I := 2$  und  $n_1 = n_2 = 3$  an.
6. Erläutern Sie den Unterschied zwischen dem Modell der einfaktoriellen Varianzanalyse und dem Modell der additiven einfaktoriellen Kovarianzanalyse.
7. Geben Sie die Definition des Modells der einfaktoriellen Kovarianzanalyse (EKA) mit Interaktion wieder.
8. Erläutern Sie die Bedeutung der Parameter  $\mu_0$ ,  $\alpha_i$ ,  $\beta_0$  und  $\gamma_i$  im Modell der EKA mit Interaktion.
9. Geben Sie die Designmatrixform des Modells der EKA mit Interaktion für  $I := 2$  und  $n_1 = n_2 = 3$  an.
10. Erläutern Sie den Unterschied zwischen dem Modell der additiven einfaktoriellen Kovarianzanalyse und dem Modell der einfaktoriellen Kovarianzanalyse mit Interaktion.