



# Evaluation und Metaanalyse

MSc Klinische Psychologie und Psychotherapie

SoSe 2024

Prof. Dr. Dirk Ostwald

## (6) Mehrebenenanalyse


## Multizentrenstudie

- Studie zum Effekt von Therapiestundenanzahl auf Reduktion der Depressionssymptomatik
- Multizentrendesign mit  $m = 4$  Hochschulambulanzen mit jeweils  $n_i = 5$  Patient:innen
- Pre-Post-BDI-II Differenz  $\delta$ BDI als primäres Ergebnismaß (Positive Werte = Reduktion)
- HSA: Hochschulambulanz, ATS: Anzahl Therapiestunden, BDI: Pre-Post-BDI-II Differenz

	HSA	ATS	BDI
1	1	19	39
2	1	13	28
3	1	14	31
4	1	16	40
5	1	19	41
6	2	17	27
7	2	24	37
8	2	24	35
9	2	22	33
10	2	21	30
11	3	21	16
12	3	22	24
13	3	22	19
14	3	27	28
15	3	24	22
16	4	33	22
17	4	30	19
18	4	32	18
19	4	35	22
20	4	29	22

# Analyse einer Multizentrenstudie mit nlme

## Multizentrenstudie



Zur Analyse wollen wir das R Paket `nlme` nach Pinheiro and Bates (2000) nutzen.

```
install.packages("nlme") # Installation des R Pakets  
library(nlme)           # Invokation der R Pakets
```

# Analyse einer Multizentrenstudie mit nlme

## lm() in R

- `lm(formula, data)` erlaubt das evaluieren linearer Modelle der Form

$$y = X\beta + \varepsilon \text{ mit } \varepsilon \sim N(0_n, \sigma^2 I_n) : \quad (1)$$

- `formula` spezifiziert die Form und die Variablen des Modells als R Formel.
- `data` spezifiziert die Daten der Variablen des Modells als R Dataframe.

## lmList() in nlme

- `lmList(formula | grouping, data)` erlaubt das evaluieren gruppenspezifischer linearer Modelle

$$y_i = X_i \beta_i + \varepsilon_i \text{ mit } \varepsilon_i \sim N(0_{n_i}, \sigma_i^2 I_{n_i}) \text{ für } i = 1, \dots, m : \quad (2)$$

- `formula` spezifiziert die Form und die Variablen jedes der  $m$  Modelle als R Formel.
- `grouping` bildet die Datengruppierungen als R Faktor ab.
- `data` spezifiziert die Daten der Variablen des Modells als R Dataframe.

## lme() in nlme

- `lme(fixed, data, random)` erlaubt das evaluieren von Linear Mixed Models der form

$$y = X_f \beta_f + X_r \beta_r + \varepsilon \text{ mit } \beta_r \sim N(0_q, \Sigma_{\beta_r}) \text{ und } \varepsilon \sim N(0_n, \Sigma_\varepsilon) \quad (3)$$

- `fixed` spezifiziert die Form der Fixed-Effects-Modellkomponenten als R Formel.
- `data` spezifiziert die Daten der Variablen des Modells als R Dataframe.
- `random` spezifiziert die Form der Random-Effects-Modellkomponenten als erweiterte R Formel.

# Analyse einer Multizentrenstudie mit nlme

## Evaluation eines einfachen linearen Regressionsmodells

### Strukturelle Form

- Wir vernachlässigen zunächst die Gruppenstruktur (Hochschulambulanzvariation) des Datensatzes.
- Wir modellieren den  $i$ ten BDI-Wert  $y_i$  als Funktion des  $i$ ten ATS-Wertes  $x_i$  als

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \text{ mit } \varepsilon_i \sim N(0, \sigma^2) \text{ für } i = 1, \dots, n \quad (4)$$

### Designmatrixform

- In Matrixform betrachten wir also das Modell

$$y = X\beta + \varepsilon \Leftrightarrow \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix} \text{ mit } \varepsilon \sim N(0_{20}, \sigma^2 I_{20}) \quad (5)$$

Wir fassen den Datensatz also mithilfe folgender Parameterschätzer zusammen:

Parameterschätzer	Interpretation
$\hat{\beta}_0$	Interzeptparameterschätzer/Symptomreduktion bei 0 Therapiestunden
$\hat{\beta}_1$	Steigungsparameterschätzer/Symptomreduktion pro 1 Therapiestunde
$\hat{\sigma}^2$	Varianzparameterschätzer/Residuelle, durch das Modell unerklärte, Varianz

# Analyse einer Multizentrenstudie mit nlme

## Evaluation eines einfachen linearen Regressionsmodells


```
D = read.csv("./6_Daten/BDI.csv") # Einlesen des Datensatzes
M = lm(BDI ~ ATS, D) # Einfache lineare Regression
S = summary(M) # Modellschätzungsergebnisse
X = model.matrix(M) # Designmatrix
beta_hat = as.matrix(M$coefficients) # Betaparameterschätzer
sigsqr_hat = S$sigma**2 # Varianzparameterschätzer
```

### Designmatrix

```
(Intercept) ATS
1          1  19
2          1  13
3          1  14
4          1  16
5          1  19
6          1  17
7          1  24
8          1  24
9          1  22
10         1  21
11         1  21
12         1  22
13         1  22
14         1  27
15         1  24
16         1  33
17         1  30
18         1  32
19         1  35
20         1  29
attr(,"assign")
[1] 0 1
```

# Analyse einer Multizentrenstudie mit nlme

## Evaluation eines einfachen linearen Regressionsmodells



Betaparameterschätzer : 43.2 -0.67

Varianzparameterschätzer : 47.88

- Keine Berücksichtigung der Gruppenstruktur (Hochschulambulanzvariation)
- Steigungsparameterschätzer  $\hat{\beta}_1$  legt Abnahme der Symptomreduktion mit Therapiedauer nahe
- Dateninspektion zeigt aber einen Anstieg der Symptomreduktion mit Therapiestunden für jede HSA
- Das Modell ist für den betrachteten Anwendungsfall sicherlich nicht ideal



# Analyse einer Multizentrenstudie mit nlme

## Evaluation eines einfaktoriellen Varianzanalysemodells

### Strukturelle Form

- Wir vernachlässigen den Effekt der Therapiedauer und betrachten lediglich den Effekt der Hochschulambulanz
- Wir modellieren den  $j$ ten Datenwert in der  $i$ ten Gruppe als

$$y_{1j} = \mu_0 + \varepsilon_{1j} \text{ und } y_{ij} = \mu_0 + \alpha_i + \varepsilon_{ij} \text{ für } i = 2, 3, 4 \text{ mit } \varepsilon_{ij} \sim N(0, \sigma^2) \text{ für } i = 1, \dots, m, j = 1, \dots, n_i$$

### Designmatrixform

- In Designmatrixform betrachten wir also das Modell

$$y = X\beta + \varepsilon \Leftrightarrow \begin{pmatrix} y_{11} \\ \vdots \\ y_{15} \\ y_{21} \\ \vdots \\ y_{25} \\ y_{31} \\ \vdots \\ y_{35} \\ y_{41} \\ \vdots \\ y_{45} \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} \mu_0 \\ \alpha_2 \\ \alpha_3 \\ \alpha_4 \end{pmatrix} + \begin{pmatrix} \varepsilon_{11} \\ \vdots \\ \varepsilon_{15} \\ \varepsilon_{21} \\ \vdots \\ \varepsilon_{25} \\ \varepsilon_{31} \\ \vdots \\ \varepsilon_{35} \\ \varepsilon_{41} \\ \vdots \\ \varepsilon_{45} \end{pmatrix} \text{ mit } \varepsilon \sim N(0_{20}, \sigma^2 I_{20}) \quad (6)$$

## Evaluation eines einfaktoriellen Varianzanalysemodells

Wir fassen den Datensatz also mithilfe folgender Parameterschätzer zusammen:

Parameterschätzer	Interpretation
$\hat{\mu}_0$	Erwartungswertschätzer für die Symptomreduktion in der Referenzgruppe HSA 1
$\hat{\alpha}_2$	Schätzer für die Erwartungswertdifferenz für die Symptomreduktion zwischen HSA 2 und HSA 1
$\hat{\alpha}_3$	Schätzer für die Erwartungswertdifferenz für die Symptomreduktion zwischen HSA 3 und HSA 1
$\hat{\alpha}_4$	Schätzer für die Erwartungswertdifferenz für die Symptomreduktion zwischen HSA 4 und HSA 1
$\hat{\sigma}^2$	Varianzparameterschätzer/Residuelle, durch das Modell unerklärte, Varianz

```
D      = read.csv("./6_Daten/BDI.csv")      # Einlesen des Datensatzes
D$HSA  = as.factor(D$HSA)                  # Umwandlung numerischer Werte in R factor
M      = lm(BDI ~ HSA, D)                  # Einfache lineare Regression
S      = summary(M)                        # Modellschätzungsresultate
X      = model.matrix(M)                   # Designmatrix
beta_hat = as.matrix(M$coefficients)      # Betaparameterschätzer
sigsqr_hat = S$sigma**2                   # Varianzparameterschätzer
```

# Analyse einer Multizentrenstudie mit nlme


## Evaluation eines einfaktoriellen Varianzanalysemodells

### Designmatrix

```
(Intercept) HSA2 HSA3 HSA4
1           1    0    0    0
2           1    0    0    0
3           1    0    0    0
4           1    0    0    0
5           1    0    0    0
6           1    1    0    0
7           1    1    0    0
8           1    1    0    0
9           1    1    0    0
10          1    1    0    0
11          1    0    1    0
12          1    0    1    0
13          1    0    1    0
14          1    0    1    0
15          1    0    1    0
16          1    0    0    1
17          1    0    0    1
18          1    0    0    1
19          1    0    0    1
20          1    0    0    1
attr("assign")
[1] 0 1 1 1
attr("contrasts")
attr("contrasts")$HSA
[1] "contr.treatment"
```

# Analyse einer Multizentrenstudie mit `nlme`

## Evaluation eines einfaktoriellen Varianzanalysemodells



Betaparameterschätzer : 35.94 -3.54 -14.17 -15.51

Varianzparameterschätzer : 18.97

- Keine Berücksichtigung der Anzahl an Therapiestunden
- Das Modell ist vor dem Hintergrund der Frage nach dem Therapiestundeneffekt sicherlich nicht ideal
- HSA 2, HSA 3 und HSA 4 haben einer geringere Symptomereduktionserwartung als HSA 1
- Dateninspektion zeigt unterschiedliche mittlere Therapiestundenanzahlen pro HSA

## Evaluation gruppenspezifischer einfacher linearen Regressionsmodelle

### Strukturelle Form

- Wir betrachten jede der Gruppen (Hochschulambulanzen) einzeln.
- Wir modellieren den  $j$ ten BDI-Wert der  $i$ ten Gruppe  $y_{ij}$  als Funktion des  $i, j$ ten ATS-Wertes  $x_{ij}$

$$y_{ij} = \beta_{i0} + \beta_{i1} x_{ij} + \varepsilon_{ij} \text{ mit } \varepsilon_{ij} \sim N(0, \sigma_i^2) \text{ für } i = 1, \dots, m, j = 1, \dots, n_i. \quad (7)$$

- In Matrixform betrachten wir also für  $i = 1, \dots, k$

$$y_i = X_i \beta_i + \varepsilon_i \Leftrightarrow \begin{pmatrix} y_{i1} \\ \vdots \\ y_{in_i} \end{pmatrix} = \begin{pmatrix} 1 & x_{i1} \\ \vdots & \vdots \\ 1 & x_{in_i} \end{pmatrix} \begin{pmatrix} \beta_{i0} \\ \beta_{i1} \end{pmatrix} + \begin{pmatrix} \varepsilon_{i1} \\ \vdots \\ \varepsilon_{in_i} \end{pmatrix} \text{ mit } \varepsilon_i \sim N(0_{n_i}, \sigma^2 I_{n_i}) \quad (8)$$

Wir fassen den Datensatz also mithilfe folgender Parameterschätzer für jede Gruppe  $i = 1, \dots, m$  zusammen:

Parameterschätzer	Interpretation
$\hat{\beta}_{i0}$	Interzeptparameterschätzer/Symptomreduktion bei 0 Therapiestunden in HSA $i$
$\hat{\beta}_{i1}$	Steigungsparameterschätzer/Symptomreduktion pro 1 Therapiestunde in HSA $i$
$\hat{\sigma}_i^2$	Varianzparameterschätzer/Residuelle, durch das Modell unerklärte, Varianz in HSA $i$

## Evaluation gruppenspezifischer einfacher linearer Regressionsmodelle

```
library(nlme)
D          = read.csv("./6_Daten/BDI.csv")          # Einlesen des Datensatzes
M          = lmList(BDI ~ ATS | HSA, D)            # gruppenspezifische ELRs
S          = list()                                # Liste für Modellschätzungsergebnisse
X          = list()                                # Liste für Designmatrizen
beta_hat   = list()                                # Liste für Betaparameterschätzer
sigsqr_hat = list()                                # Liste für Varianzparameterschätzer
for(i in 1:length(M)){                             # Gruppeniterationen
  S[[i]]   = summary(M[[i]])                       # Modellschätzungsergebnisse
  X[[i]]   = model.matrix(M[[i]])                 # Designmatrix
  beta_hat[[i]] = as.matrix(M[[i]]$coefficients) # Betaparameterschätzer
  sigsqr_hat[[i]] = S[[i]]$sigma*2               # Varianzparameterschätzer
}
```

BDI ~ ATS | HSA ist eine erweiterte R Formel, die BDI und ATS anhand der Level des Faktors HSA partitioniert!

# Analyse einer Multizentrenstudie mit nlme


## Evaluation gruppenspezifischer einfacher linearer Regressionsmodelle

### Designmatrizen

```
(Intercept) ATS
1          1  19
2          1  13
3          1  14
4          1  16
5          1  19
attr(,"assign")
[1] 0 1
(Intercept) ATS
6          1  17
7          1  24
8          1  24
9          1  22
10         1  21
attr(,"assign")
[1] 0 1
(Intercept) ATS
11         1  21
12         1  22
13         1  22
14         1  27
15         1  24
attr(,"assign")
[1] 0 1
(Intercept) ATS
16         1  33
17         1  30
18         1  32
19         1  35
20         1  29
attr(,"assign")
[1] 0 1
```

# Analyse einer Multizentrenstudie mit nlme

## Evaluation gruppenspezifischer einfacher linearer Regressionsmodelle



HSA 1 Betaparameterschätzer	: 5.57 1.87	Varianzparameterschätzer:	9.84
HSA 2 Betaparameterschätzer	: 3.75 1.33	Varianzparameterschätzer:	2.05
HSA 3 Betaparameterschätzer	: -16.8 1.66	Varianzparameterschätzer:	6.98
HSA 4 Betaparameterschätzer	: 14.35 0.19	Varianzparameterschätzer:	5.45

- Es wird deutlich, dass die Symptomreduktion in jeder HSA mit steigender Therapiestundenanzahl zunimmt.
- Dies entspricht der Intuition bei HSA-spezifischer Dateninspektion.
- Es wird allerdings kein HSA-übergreifender Therapiestundenanzahleffekt bestimmt.
- Es wird auch kein Maß für die Varianz der Effekt zwischen den Hochschulambulanzen bestimmt.



# Analyse einer Multizentrenstudie mit nlme

## Evaluation eines Einfache-Lineare-Regression-LMMs mit zufälligem Interzeptparameter

### Strukturelle Form

- Wir modellieren den  $j$ ten Datenwert in der  $i$ ten Gruppe mit  $j = 1, \dots, 5$  und  $i = 1, \dots, 4$  als

$$y_{ij} = \beta_0 + \beta_1 x_{ij} + \beta_{0i} + \varepsilon_{ij} \text{ mit } \beta_{0i} \sim N(0, \sigma_{\beta_r}^2) \text{ mit } \varepsilon_{ij} \sim N(0, \sigma^2) \quad (9)$$

### Designmatrixform

$$y = X_f \beta_f + X_r \beta_r + \varepsilon \Leftrightarrow \begin{pmatrix} y_{11} \\ \vdots \\ y_{15} \\ y_{21} \\ \vdots \\ y_{25} \\ y_{31} \\ \vdots \\ y_{35} \\ y_{41} \\ \vdots \\ y_{45} \end{pmatrix} = \begin{pmatrix} 1 & x_{11} \\ \vdots & \vdots \\ 1 & x_{15} \\ 1 & x_{21} \\ \vdots & \vdots \\ 1 & x_{25} \\ 1 & x_{31} \\ \vdots & \vdots \\ 1 & x_{35} \\ 1 & x_{41} \\ \vdots & \vdots \\ 1 & x_{45} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix} + \begin{pmatrix} 1 & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} \beta_{01} \\ \beta_{02} \\ \beta_{03} \\ \beta_{04} \end{pmatrix} + \begin{pmatrix} \varepsilon_{11} \\ \vdots \\ \varepsilon_{15} \\ \varepsilon_{21} \\ \vdots \\ \varepsilon_{25} \\ \varepsilon_{31} \\ \vdots \\ \varepsilon_{35} \\ \varepsilon_{41} \\ \vdots \\ \varepsilon_{45} \end{pmatrix} \quad (10)$$

mit

$$\beta_r \sim N(0_4, \sigma_{\beta_r}^2 I_4) \text{ und } \varepsilon \sim N(0_{20}, \sigma^2 I_{20}) \quad (11)$$

# Analyse einer Multizentrenstudie mit nlme

## Evaluation eines Einfache-Lineare-Regression-LMMs mit zufälligem Interzeptparameter

Wir fassen den Datensatz als für  $i = 1, \dots, 4$  mithilfe folgender Parameterschätzer zusammen:

Parameterschätzer	Interpretation
$\hat{\beta}_0$	FFX-Interzept-Schätzer/HSA-übergreifende Symptomreduktion bei 0 Therapiestunden
$\hat{\beta}_1$	FFX-Steigungs-Schätzer/HSA-übergreifende Symptomreduktion pro 1 Therapiestunde
$\hat{\beta}_{0i}$	RFX-Interzept-Schätzer/HSA $i$ -spezifische Symptomreduktion bei 0 Therapiestunden
$\hat{\sigma}_{\beta_r}^2$	RFX-Varianz-Schätzer/HSA-übergreifende Interzeptvarianz
$\hat{\sigma}^2$	Datenvarianz-Schätzer/Residuelle, durch das Modell unerklärte, Varianz

```
library(nlme)
D = read.csv("../6_Daten/BDI.csv")
D$HSA = as.factor(D$HSA)
M = lme(BDI - ATS, D, random = ~ 1 | HSA)
X_f = model.matrix(M, D)
X_r = model.matrix(~ M$groups[[1]] - 1)
beta_f_hat = M$coefficients$fixed
beta_r_hat = M$coefficients$random$HSA
s_eps_hat = M$sigma**2
s_beta_r_hat = diag(getVarCov(M))
```

# R Paket  
# Einlesen des Datensatzes  
# Umwandlung numerischer Werte in R factor  
# LMM vom Einfache Lineare Regressionstyp  
# Fixed-Effects-Designmatrix  
# Random-Effects-Designmatrix  
# Fixed-Effects-Parameterschätzer  
# Random-Effects-Parameterschätzer  
# Datenvarianzkomponente  
# Random-Effects-Varianzkomponente

`random = ~ 1 | HSA` kodiert einen gruppenspezifischen zufälligen Interzeptparameter

# Analyse einer Multizentrenstudie mit nlme

---

## Evaluation eines Einfache-Lineare-Regression-LMMs mit zufälligem Interzeptparameter

### Fixed-Effects-Designmatrix

```
(Intercept) ATS
1           1  19
2           1  13
3           1  14
4           1  16
5           1  19
6           1  17
7           1  24
8           1  24
9           1  22
10          1  21
11          1  21
12          1  22
13          1  22
14          1  27
15          1  24
16          1  33
17          1  30
18          1  32
19          1  35
20          1  29
attr(,"assign")
[1] 0 1
```

# Analyse einer Multizentrenstudie mit nlme


## Evaluation eines Einfache-Lineare-Regression-LMMs mit zufälligem Interzeptparameter

### Random-Effects-Designmatrix

```
M$groups[[1]]1 M$groups[[1]]2 M$groups[[1]]3 M$groups[[1]]4
1      1      0      0      0
2      1      0      0      0
3      1      0      0      0
4      1      0      0      0
5      1      0      0      0
6      0      1      0      0
7      0      1      0      0
8      0      1      0      0
9      0      1      0      0
10     0      1      0      0
11     0      0      1      0
12     0      0      1      0
13     0      0      1      0
14     0      0      1      0
15     0      0      1      0
16     0      0      0      1
17     0      0      0      1
18     0      0      0      1
19     0      0      0      1
20     0      0      0      1
attr("assign")
[1] 1 1 1 1
attr("contrasts")
attr("contrasts")$`M$groups[[1]]`
[1] "contr.treatment"
```

# Analyse einer Multizentrenstudie mit nlme

## Evaluation eines Einfache-Lineare-Regression-LMMs mit zufälligem Interzeptparameter



```
Fixed-Effects-Parameterschätzer : -0.87 1.23  
Residuelle Varianzschätzer      : 7.65  
Random-Effects-Varianzschätzer  : 228.4
```

```
[1] "Random-Effects-Parameterschätzer"
```

```
(Intercept)  
1  16.792256  
2   6.689060  
3  -5.828815  
4 -17.652501
```

- Es wird deutlich, dass die Symptomreduktion über HSAs mit steigender Therapiestundenanzahl zunimmt.
- Die Annahme, dass die Symptomreduktionsrate in jeder HSA gleich ist, mag etwas stark sein (vgl. HSA 4).

# Analyse einer Multizentrenstudie mit nlme

## Evaluation eines ELR-LMMs mit zufälligen Interzept- und Steigungsparametern

### Strukturelle Form

- Wir modellieren den  $j$ ten Datenwert in der  $i$ ten Gruppe mit  $j = 1, \dots, 5$  und  $i = 1, \dots, 4$  als

$$y_{ij} = \beta_0 + \beta_1 x_{ij} + \beta_{0i} + \beta_{1i} x_{ij} + \varepsilon_{ij} \text{ mit } \beta_{ki} \sim N(0, \sigma_{\beta_r}^2) \text{ für } k = 0, 1 \text{ und } \varepsilon_{ij} \sim N(0, \sigma^2) \quad (12)$$

### Designmatrixform

$$y = X_f \beta_f + X_r \beta_r + \varepsilon \Leftrightarrow \quad (13)$$

$$\begin{pmatrix} y_{11} \\ \vdots \\ y_{15} \\ y_{21} \\ \vdots \\ y_{25} \\ y_{31} \\ \vdots \\ y_{35} \\ y_{41} \\ \vdots \\ y_{45} \end{pmatrix} = \begin{pmatrix} 1 & x_{11} \\ \vdots & \vdots \\ 1 & x_{15} \\ 1 & x_{21} \\ \vdots & \vdots \\ 1 & x_{25} \\ 1 & x_{31} \\ \vdots & \vdots \\ 1 & x_{35} \\ 1 & x_{41} \\ \vdots & \vdots \\ 1 & x_{45} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix} + \begin{pmatrix} 1 & x_{11} & 0 & 0 & 0 & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{15} & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & x_{21} & 0 & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 1 & x_{25} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & x_{31} & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & 1 & x_{35} & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & x_{41} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & x_{45} \end{pmatrix} \begin{pmatrix} \beta_{01} \\ \beta_{11} \\ \beta_{02} \\ \beta_{12} \\ \beta_{03} \\ \beta_{13} \\ \beta_{04} \\ \beta_{14} \end{pmatrix} + \begin{pmatrix} \varepsilon_{11} \\ \vdots \\ \varepsilon_{15} \\ \varepsilon_{21} \\ \vdots \\ \varepsilon_{25} \\ \varepsilon_{31} \\ \vdots \\ \varepsilon_{35} \\ \varepsilon_{41} \\ \vdots \\ \varepsilon_{45} \end{pmatrix} \quad (14)$$

mit

$$\beta_r \sim N(0_8, \sigma_{\beta_r}^2 I_8) \text{ und } \varepsilon \sim N(0_{20}, \sigma^2 I_{20}) \quad (15)$$

# Analyse einer Multizentrenstudie mit nlme

## Evaluation eines ELR-LMMs mit zufälligen Interzept- und Steigungsparametern


Wir fassen den Datensatz als für  $i = 1, \dots, 4$  mithilfe folgender Parameterschätzer zusammen:

Parameterschätzer	Interpretation
$\hat{\beta}_0$	FFX-Interzept-Schätzer/HSA-übergreifende Symptomreduktion bei 0 Therapiestunden
$\hat{\beta}_1$	FFX-Steigungs-Schätzer/HSA-übergreifende Symptomreduktion pro 1 Therapiestunde
$\hat{\beta}_{0i}$	RFX-Interzept-Schätzer/HSA $i$ -spezifische Symptomreduktion bei 0 Therapiestunden
$\hat{\beta}_{1i}$	RFX-Steigungs-Schätzer/HSA $i$ -spezifische Symptomreduktion pro 1 Therapiestunde
$\hat{\sigma}_{\beta_r}^2$	RFX-Varianz-Schätzer/HSA-übergreifende Interzept- und Steigungsvarianz
$\hat{\sigma}^2$	Datenvarianz-Schätzer/Residuelle, durch das Modell unerklärte, Varianz

```
library(nlme) # R Paket
ctrl         = lmeControl(opt = "optim", maxIter = 100) # Anzahl an ReML Iterationen
D            = read.csv("./6_Daten/BDI.csv")           # Einlesen des Datensatzes
D$HSA       = as.factor(D$HSA)                       # Umwandlung numerischer Werte in R factor
M           = lme(BDI ~ ATS, D, random = ~ ATS | HSA, control = ctrl) # LMM vom Einfache Lineare Regressionstyp
X_f         = model.matrix(M,D)                      # Fixed-Effects-Designmatrix
beta_f_hat  = M$coefficients$fixed                  # Fixed-Effects-Parameterschätzer
beta_r_hat  = M$coefficients$random$HSA            # Random-Effects-Parameterschätzer
sigsqr_eps_hat = M$sigma**2                        # Datenvarianzkomponente
```

# Analyse einer Multizentrenstudie mit nlme

## Evaluation eines ELR-LMMs mit zufälligen Interzept- und Steigungsparametern



```
Fixed-Effects-Parameterschätzer : 1.74 1.21  
Residuelle Varianzschätzer      : 7.65  
Random-Effects-Varianzschätzer  : 228.4
```

```
[1] "Random-Effects-Parameterschätzer"
```

```
(Intercept)    ATS  
1  4.438574  0.6167610  
2  1.116603  0.1531704  
3 -2.062339 -0.2545769  
4 -3.492838 -0.5153544
```

- Es wird deutlich, dass die Symptomreduktion über HSAs mit steigender Therapiestundenanzahl zunimmt.
- Die Symptomreduktionsrate varriieren nicht unabhängig über HSAs, sondern durch andere HSAs informiert.



## Appendix

# Appendix

## R Formeln

Modelle der Form  $y = X\beta + \varepsilon$  mit  $\varepsilon \sim N(0_n, \sigma^2 I_n)$  werden in R symbolisch durch `formulas` dargestellt

`Daten ~ Term 1 + Term 2 + ... + Term k`

- Der `~` Operator trennt die linke Seite und rechte Seite einer `formula`
- `Daten` wird zur Identifikation der abhängigen Variable  $y$  genutzt
- `Term 1 + Term 2 + ... + Term k` dient der Spezifikation der Spalten der Designmatrix  $X$
- Die `formulas` Syntax geht zurück auf Wilkinson and Rogers (1973) und Chambers and Hastie (1992)

Terme können numerische Prädiktoren oder kategoriale Faktoren (R factors) sein

Die `formula` Syntax ist symbolisch, zur Laufzeit müssen die Prädiktoren und Faktoren nicht spezifiziert sein

Essentielle Operatoren in `formulas` sind `+` und `:`

- `+` fügt der Designmatrix Prädiktoren hinzu, `:` dient der Spezifikation von Interaktionen

Nichtessentielle Operatoren in `formulas` sind `*`, `/`, `%in%`, `-` und `^`

- Für zwei Faktoren `f1` und `f2` gilt beispielsweise `f1*f2 = f1 + f2 + f1:f2`

## R Formeln

Beispiele mit  $x_1$ ,  $x_2$  als numerische Vektoren und  $f_1$ ,  $f_2$  als R Faktoren

```
formula(y ~ x1)      # Spezifikation einer einfachen linearen Regression mithilfe der formula() Funktion
y ~ x1              # Aufruf der formula() Funktion ist aber nicht nötig, R erkennt formulas auch so
y ~ 1 + x1         # Explizite Interzeptdefinition bei einfacher linearer Regression, nicht nötig
y ~ 0 + x1         # Verzicht auf Interzeptdefinition bei einfacher linearer Regression
y ~ 1 + x1 + x2    # Multiple Regression mit zwei Regressoren und expliziter Interzeptdefinition
y ~ f1             # Einfaktorielles ANOVA Design
y ~ f1 + f2        # Additives zweifaktorielles ANOVA Design
y ~ f1 + f2 + f1:f2 # Zweifaktorielles ANOVA Design mit Interaktion
y ~ f1 + x1        # Additives einfaktorielles ANCOVA Design mit einer Kovariate
y ~ f1 + x1 + f1:x1 # Einfaktorielles ANCOVA Design mit einer Kovariate und Interaktion
```

Wir betrachten im Folgenden die durch diese `formulas` erzeugten Designmatrizen  $X \in \mathbb{R}^{n \times p}$ .

# Appendix

## R Formeln

### Einfache Lineare Regression

```
n = 12 # Anzahl Datenpunkte
x1 = 1:n # Regressor
y = rnorm(n) # Beispieldaten
D = data.frame(y = y, x1 = x1) # Dataframe
M = lm(y ~ x1, D) # Modellevaluation
X = model.matrix(M) # Designmatrix
```

```
(Intercept) x1
1          1  1
2          1  2
3          1  3
4          1  4
5          1  5
6          1  6
7          1  7
8          1  8
9          1  9
10         1 10
11         1 11
12         1 12
attr(,"assign")
[1] 0 1
```

# Appendix

## R Formeln

### Einfache Lineare Regression mit expliziter Interzeptdefinition

```
n = 12 # Anzahl Datenpunkte
x1 = 1:n # Regressor
y = rnorm(n) # Beispieldaten
D = data.frame(y = y, x1 = x1) # Dataframe
M = lm(y ~ - 1 + x1, D) # Modellevaluation
X = model.matrix(M) # Designmatrix
```

```
(Intercept) x1
1 1 1
2 1 2
3 1 3
4 1 4
5 1 5
6 1 6
7 1 7
8 1 8
9 1 9
10 1 10
11 1 11
12 1 12
attr(,"assign")
[1] 0 1
```

# Appendix

## R Formeln

### Einfache Lineare Regression mit Verzicht auf Interzeptdefinition

```
n = 12 # Anzahl Datenpunkte
x1 = 1:n # Regressor
y = rnorm(n) # Beispieldaten
D = data.frame(y = y, x1 = x1) # Dataframe
M = lm(y ~ 0 + x1, D) # Modellevaluation
X = model.matrix(M) # Designmatrix
```

```
      x1
1      1
2      2
3      3
4      4
5      5
6      6
7      7
8      8
9      9
10     10
11     11
12     12
attr(,"assign")
[1] 1
```

# Appendix

## R Formeln

### Multiple Regression mit zwei Regressoren und expliziter Interzeptdefinition

```
n = 12 # Anzahl Datenpunkte
x1 = 1:n # Regressor 1
x2 = (1:n)+5 # Regressor 2
y = rnorm(n) # Beispieldaten
D = data.frame(y = y, x1 = x1, x2 = x2) # Dataframe
M = lm(y ~ 1 + x1 + x2, D) # Modellevaluation
X = model.matrix(M) # Designmatrix
```

```
(Intercept) x1 x2
1 1 1 6
2 1 2 7
3 1 3 8
4 1 4 9
5 1 5 10
6 1 6 11
7 1 7 12
8 1 8 13
9 1 9 14
10 1 10 15
11 1 11 16
12 1 12 17
attr(,"assign")
[1] 0 1 2
```

# Appendix

## R Formeln

### Einfaktorielles ANOVA Design mit drei Faktorleveln

```
n = 12 # Anzahl Datenpunkte
f1 = as.factor(c(1,1,1,1,2,2,2,2,3,3,3,3)) # Faktorlevel der Datenpunkte
y = rnorm(n) # Beispieldaten
D = data.frame(y = y, f1 = f1) # Dataframe
M = lm(y ~ f1, D) # Modellevaluation
X = model.matrix(M) # Designmatrix
```

```
(Intercept) f12 f13
1          1  0  0
2          1  0  0
3          1  0  0
4          1  0  0
5          1  1  0
6          1  1  0
7          1  1  0
8          1  1  0
9          1  0  1
10         1  0  1
11         1  0  1
12         1  0  1
attr(,"assign")
[1] 0 1 1
attr(,"contrasts")
attr(,"contrasts")$f1
[1] "contr.treatment"
```



# Appendix

## R Formeln

### Zweifaktorielles additives ANOVA Design mit jeweils zwei Faktorleveln

```
n = 12 # Anzahl Datenpunkte
f1 = as.factor(c(1,1,1,1,1,1,2,2,2,2,2,2)) # Faktor-1-Level der Datenpunkte
f2 = as.factor(c(1,1,1,2,2,2,1,1,1,2,2,2)) # Faktor-2-Level der Datenpunkte
y = rnorm(n) # Beispieldaten
D = data.frame(y = y, f1 = f1, f2 = f2) # Dataframe
M = lm(y ~ f1 + f2, D) # Modellevaluation
X = model.matrix(M) # Designmatrix
```

```
(Intercept) f12 f22
1          1  0  0
2          1  0  0
3          1  0  0
4          1  0  1
5          1  0  1
6          1  0  1
7          1  1  0
8          1  1  0
9          1  1  0
10         1  1  1
11         1  1  1
12         1  1  1
attr(,"assign")
[1] 0 1 2
attr(,"contrasts")
attr(,"contrasts")$f1
[1] "contr.treatment"

attr(,"contrasts")$f2
[1] "contr.treatment"
```

# Appendix

## R Formeln

### Zweifaktorielles additives ANOVA Design mit Interaktion

```
n = 12 # Anzahl Datenpunkte
f1 = as.factor(c(1,1,1,1,1,1,1,2,2,2,2,2)) # Faktor-1-Level der Datenpunkte
f2 = as.factor(c(1,1,1,1,2,2,2,1,1,1,2,2)) # Faktor-2-Level der Datenpunkte
y = rnorm(n) # Beispieldaten
D = data.frame(y = y, f1 = f1, f2 = f2) # Dataframe
M = lm(y ~ f1 + f2 + f1:f2, D) # Modellevaluation
X = model.matrix(M) # Designmatrix
```

```
(Intercept) f12 f22 f12:f22
1          1  0  0          0
2          1  0  0          0
3          1  0  0          0
4          1  0  1          0
5          1  0  1          0
6          1  0  1          0
7          1  1  0          0
8          1  1  0          0
9          1  1  0          0
10         1  1  1          1
11         1  1  1          1
12         1  1  1          1
attr(,"assign")
[1] 0 1 2 3
attr(,"contrasts")
attr(,"contrasts")$f1
[1] "contr.treatment"

attr(,"contrasts")$f2
[1] "contr.treatment"
```

# Appendix

## R Formeln

### Additives einfaktorielles ANCOVA Design mit einer Kovariate

```
n = 12 # Anzahl Datenpunkte
f1 = as.factor(c(1,1,1,1,1,1,2,2,2,2,2,2)) # Faktorlevel der Datenpunkte
x1 = 1:n # Kovariatenwerte der Datenpunkte
y = rnorm(n) # Beispieldaten
D = data.frame(y = y, f1 = f1, x1 = x1) # Dataframe
M = lm(y ~ f1 + x1, D) # Modellevaluation
X = model.matrix(M) # Designmatrix
```

```
(Intercept) f12 x1
1          1  0  1
2          1  0  2
3          1  0  3
4          1  0  4
5          1  0  5
6          1  0  6
7          1  1  7
8          1  1  8
9          1  1  9
10         1  1 10
11         1  1 11
12         1  1 12
attr(,"assign")
[1] 0 1 2
attr(,"contrasts")
attr(,"contrasts")$f1
[1] "contr.treatment"
```

# Appendix

## R Formeln

### Einfaktorielles ANCOVA Design mit einer Kovariate und Interaktion

```
n = 12 # Anzahl Datenpunkte
f1 = as.factor(c(1,1,1,1,1,1,2,2,2,2,2,2)) # Faktorlevel der Datenpunkte
x1 = 1:n # Kovariatenwerte der Datenpunkte
y = rnorm(n) # Beispieldaten
D = data.frame(y = y, f1 = f1, x1 = x1) # Dataframe
M = lm(y ~ f1 + x1 + f1:x1, D) # Modellevaluation
X = model.matrix(M) # Designmatrix
```

```
(Intercept) f12 x1 f12:x1
1 1 0 1 0
2 1 0 2 0
3 1 0 3 0
4 1 0 4 0
5 1 0 5 0
6 1 0 6 0
7 1 1 7 7
8 1 1 8 8
9 1 1 9 9
10 1 1 10 10
11 1 1 11 11
12 1 1 12 12
attr(,"assign")
[1] 0 1 2 3
attr(,"contrasts")
attr(,"contrasts")$f1
[1] "contr.treatment"
```

- Chambers, John M., and Trevor Hastie, eds. 1992. *Statistical Models in S*. Wadsworth & Brooks/Cole Computer Science Series. Pacific Grove, Calif: Wadsworth & Brooks/Cole Advanced Books & Software.
- Pinheiro, José C., and Douglas M. Bates. 2000. *Mixed-Effects Models in S and S-PLUS*. Statistics and Computing. New York: Springer.
- Wilkinson, G. N., and C. E. Rogers. 1973. "Symbolic Description of Factorial Models for Analysis of Variance." *Applied Statistics* 22 (3): 392. <https://doi.org/10.2307/2346786>.