



# Evaluation und Metaanalyse

MSc Klinische Psychologie und Psychotherapie

SoSe 2024

Prof. Dr. Dirk Ostwald

## (5) Linear Mixed Models

---

## Überblick

- Linear Mixed Models sind eine Weiterentwicklung des Allgemeinen Linearen Modells (ALM).
- Durch iterative Schätzverfahren sind Linear Mixed Models in den letzten 50 Jahren sehr populär geworden.
- In **R** sind Linear Mixed Models durch die Verfügbarkeit der Pakete `nlme` und `lme4` sehr verbreitet.
- Klassische Anwendungen von Linear Mixed Models sind Mehrebenen- und Longitudinalanalysen.
- Fixed- und Random-Effects Modelle der Metaanalyse sind spezielle Linear Mixed Models.
- Die Restricted Maximum-Likelihood-Schätzung ist eng mit der Theorie der Linear Mixed Models verwoben.
- Viele weitere Modelle sind Spezialfälle von Linear Mixed Models, z.B. die Bayesianische ALM Schätzung.
- Linear Mixed Models sind die state-of-the-art Inferenzmodelle in vielen Anwendungsfeldern

Wir formulieren zunächst ein allgemeines Linear Mixed Model.

Zur Schätzung eines eines Linear Mixed Models betrachten wir dann

- die Generalisierte Kleinste-Quadrate Schätzung der Fixed Effects und ihre Konfidenzintervalle,
- den bedingten Erwartungswert der Random-Effects, sowie
- die Varianzkomponentenschätzung mit Restricted Maximum-Likelihood.

Wir betrachten schließlich die Formulierung und Schätzung von Linear Mixed Models mithilfe des **R** Pakets `nlme`.

---

## **Modellformulierung**

Generalisierte Kleinste-Quadrate Schätzung der Fixed-Effects

Varianzkomponentenschätzung mit Restricted Maximum-Likelihood

Bedingter Erwartungswert der Random-Effects

Selbstkontrollfragen

## Definition (Linear Mixed Model)

Es sei

$$y = X_f \beta_f + X_r \beta_r + \varepsilon, \quad (1)$$

wobei

- $y$  ein  $n$ -dimensionaler beobachtbarer Zufallsvektor ist, der *Daten* genannt wird,
- $X_f \in \mathbb{R}^{n \times p}$  eine vorgegebene Matrix ist, die *Fixed-Effects-Designmatrix* genannt wird,
- $\beta_f \in \mathbb{R}^p$  ein unbekannter fester Vektor ist, der *Fixed Effects* genannt wird,
- $X_r \in \mathbb{R}^{n \times q}$  eine vorgegebene Matrix ist, die *Random-Effects-Designmatrix* genannt wird,
- $\beta_r$  ein  $q$ -dimensionaler latenter Zufallsvektor ist der *Random Effects* genannt wird und für den gilt, dass

$$\beta_r \sim N(0_q, \Sigma_{\beta_r}) \text{ mit } \Sigma_{\beta_r} \in \mathbb{R}^{q \times q} \text{ p.d.}, \quad (2)$$

- $\varepsilon$  ein  $n$ -dimensionaler latenter Zufallsvektor ist, der *Zufallsfehler* genannt wird und für den gilt, dass

$$\varepsilon \sim N(0_n, \Sigma_\varepsilon) \text{ mit } \Sigma_\varepsilon \in \mathbb{R}^{n \times n} \text{ p.d. und unabhängig von } \beta_r. \quad (3)$$

Dann heißt (1) *Linear Mixed Model*.

Bemerkungen

- Man bezeichnet Darstellung des Linear Mixed Models in dieser Definition auch als *strukturelle Form* bezeichnen.
- Häufig gelten  $\Sigma_{\beta_r} := \sigma_{\beta_r}^2 I_q$  mit  $\sigma_{\beta_r}^2 > 0$  und  $\Sigma_\varepsilon := \sigma_\varepsilon^2 I_n$  mit  $\sigma_\varepsilon^2 > 0$ .

## Anwendungsbeispiel

- Studie zum Effekt von Therapiestundenanzahl auf Reduktion der Depressionssymptomatik
- Multizentrendesign mit  $k = 4$  Hochschulambulanzen mit jeweils  $n_i = 5$  Patient:innen
- Pre-Post-BDI-II Differenz  $\Delta\text{BDI}$  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

## Anwendungsbeispiel

```
# Datengeneration
library(MASS)
library(Matrix)
set.seed(0)
k          = 4
n_i       = 5
n         = k*n_i
x         = matrix(rep(NA,n), ncol = k)
x[,1]     = round(runif(n_i, min = 10, max = 20))
x[,2]     = round(runif(n_i, min = 15, max = 25))
x[,3]     = round(runif(n_i, min = 20, max = 30))
x[,4]     = round(runif(n_i, min = 25, max = 35))
Xi        = array(rep(NA,n*k), dim = c (n_i,2,k))
for(i in 1:k){
  Xi[, ,i] = matrix(c(rep(1,n_i),x[,i]), ncol = 2)}
X_f       = rbind(Xi[, ,1],Xi[, ,2],Xi[, ,3],Xi[, ,4])
beta_f    = matrix(c(5,1), nrow = 2)
X_r       = as.matrix(bdiag(Xi[, ,1],Xi[, ,2],Xi[, ,3],Xi[, ,4]))
beta_r    = matrix(c(15,0,5,0,-5,0,-15,0))
s_eps     = 15
eps       = mvnrm(1,rep(0,n), s_eps*diag(n))
y         = X_f %*% beta_f + X_r %*% beta_r + eps
HSA       = kronecker(c(1,2,3,4), rep(1,n_i))
D         = data.frame(HSA = HSA, ATS = X_f[,2], BDI = y)
write.csv(D, "./5_Daten/BDI.csv", row.names = FALSE)
```

```
# multivariate Normalverteilung
# Blockdiagonalmatrizen
# Zufallszahlengeneratorzustand
# Anzahl Zentren
# Anzahl Patient:innen pro Zentrum
# Gesamtanzahl an Patient:innen
# Therapiedauerarray
# Therapiedauer Hochschulambulanz 1
# Therapiedauer Hochschulambulanz 2
# Therapiedauer Hochschulambulanz 3
# Therapiedauer Hochschulambulanz 4
# Zentrumspezifische Regressionsmatrizenarray
# Zentreniterationen
# Zentrumspezifische Regressionmatrix
# Fixed-Effects-Designmatrix
# Fixed-Effects-Parameter
# Random-Effects-Designmatrix
# Random-Effects-Parameter
# Varianzkomponente
# Fehlervektor
# Datengeneration
# Hochschulambulanzfaktor
# Dataframe
# Speichern
```

## Anwendungsbeispiel





## Definition (Verteilungsdarstellung des Linear Mixed Models)

Gegeben sei ein Linear Mixed Model

$$y = X_f \beta_f + X_r \beta_r + \varepsilon \text{ mit } \beta_r \sim N(0_q, \Sigma_{\beta_r}) \text{ und } \varepsilon \sim N(0_n, \Sigma_\varepsilon). \quad (4)$$

Dann nennt man die äquivalente Darstellung dieses Modells mit der marginalen Verteilung

$$\beta_r \sim N(0_q, \Sigma_{\beta_r}) \quad (5)$$

und der bedingten Verteilung

$$y | \beta_r \sim N(X_f \beta_f + X_r \beta_r, \Sigma_\varepsilon) \quad (6)$$

die Verteilungsdarstellung des Linear Mixed Models

### Bemerkungen

- Die Äquivalenz folgt mit dem Theorem zur linear-affinen Transformation multivariater Normalverteilungen.
- Intuitiv beschreibt der Ausdruck  $y = X_f \beta_f + X_r \beta_r + \varepsilon$  vor allem eine bedingte Verteilung.
- Die Fehlerkovarianzmatrix  $\Sigma_\varepsilon$  ist die Kovarianzmatrix dieser bedingten Verteilung.

## Theorem (Gemeinsame Verteilung des Linear Mixed Models)

Gegeben sei ein Linear Mixed Model. Dann gilt für die gemeinsame Verteilung von Daten und Random Effects, dass

$$\begin{pmatrix} \beta_r \\ \mathbf{y} \end{pmatrix} \sim N(\mu_{\beta_r, \mathbf{y}}, \Sigma_{\beta_r, \mathbf{y}}) \quad (7)$$

mit

$$\mu_{\beta_r, \mathbf{y}} := \begin{pmatrix} 0_q \\ X_f \beta_f \end{pmatrix} \in \mathbb{R}^{q+n} \text{ und } \Sigma_{\beta_r, \mathbf{y}} := \begin{pmatrix} \Sigma_{\beta_r} & \Sigma_{\beta_r} X_r^T \\ X_r \Sigma_{\beta_r} & X_r \Sigma_{\beta_r} X_r^T + \Sigma_\varepsilon \end{pmatrix} \in \mathbb{R}^{(q+n) \times (q+n)} \quad (8)$$

### Beweis

Die gemeinsame Verteilung des Linear Mixed Models ergibt sich direkt durch Anwendung des Theorems zu Gemeinsamen Normalverteilungen auf die Verteilungsdarstellung des Linear Mixed Models.

□

## Theorem (Marginale Datenverteilung des Linear Mixed Models)

Gegeben sei ein Linear Mixed Model. Dann gilt für die marginale Verteilung der Daten, dass

$$y \sim N(\mu_y, \Sigma_y) \quad (9)$$

mit

$$\mu_y := X_f \beta_f \in \mathbb{R}^n \text{ und } \Sigma_y := X_r \Sigma_{\beta_r} X_r^T + \Sigma_\varepsilon \in \mathbb{R}^{n \times n} \quad (10)$$

### Beweis

Die Aussage ergibt sich direkt aus dem Theorem zur Gemeinsamen Verteilung des Linear Mixed Models und dem Theorem zu Marginalen Normalverteilungen.

□

### Bemerkungen

- Linear Mixed Models erlauben es, nicht-sphärische Kovarianzmatrixstrukturen zu modellieren.
- Gilt speziell  $\Sigma_{\beta_r} := \sigma_{\beta_r}^2 I_q, \sigma_{\beta_r}^2 > 0$  und  $\Sigma_\varepsilon := \sigma_\varepsilon^2 I_n, \sigma_\varepsilon^2 > 0$ , so folgt

$$y \sim N\left(X_f \beta_f, \sigma_{\beta_r}^2 X_r X_r^T + \sigma_\varepsilon^2 I_n\right) \quad (11)$$

- Parameter wie  $\sigma_{\beta_r}^2$  und  $\sigma_\varepsilon^2$  nennt man *Kovarianzkomponenten*.

## Definition (Hierarchische Darstellung des Linear Mixed Models)

Gegeben sei ein Linear Mixed Model

$$y = X_f \beta_f + X_r \beta_r + \varepsilon \text{ mit } \beta_r \sim N(0_q, \Sigma_{\beta_r}) \text{ und } \varepsilon \sim N(0_n, \Sigma_\varepsilon). \quad (12)$$

Dann nennt man die äquivalente Darstellung dieses Modells in der Form

$$\begin{aligned} \beta_r &= 0_q + \eta && \text{mit } \eta \sim N(0_q, \Sigma_{\beta_r}) \Leftrightarrow \beta_r \sim N(0_q, \Sigma_{\beta_r}) \\ y &= X_f \beta_f + X_r \beta_r + \varepsilon \text{ mit } \varepsilon \sim N(0_n, \Sigma_\varepsilon) \Leftrightarrow y | \beta_r \sim N(X_f \beta_f + X_r \beta_r, \Sigma_\varepsilon) \end{aligned} \quad (13)$$

die *hierarchische Darstellung des Linear Mixed Models*

Bemerkung

- Man nennt diese Darstellung auch ein *Mehrebenenmodell*.
- Es ist leicht, sich Linear Mixed Models mit mehr als den hier spezifizierten zwei Ebenen vorzustellen.
- Die obigen Verteilungsaussagen gelten natürlich auch für die Hierarchische Form des Linear Mixed Models.

## Theorem (Populationsparameterdarstellung des Linear Mixed Models)

Mit den Definitionen des Linear Mixed Models und einer Matrix  $X \in \mathbb{R}^{q \times p}$  sei

$$y = X_r \beta + \varepsilon \text{ mit } \beta := X \beta_f + \beta_r, X_f := X_r X \text{ und } \beta \sim N(X \beta_f, \Sigma_{\beta_r}) \text{ und } \varepsilon \sim N(0_n, \Sigma_\varepsilon) \quad (14)$$

Dann ist (14) äquivalent zu (1) und wir nennen (14) die *Populationsparameterdarstellung des Linear Mixed Models* mit *Populationsparameter*  $\beta_f \in \mathbb{R}^p$ .

### Bemerkungen

- In (14) denkt man sich  $\beta$  aus einer Population mit Erwartungswert  $X \beta_f$  realisiert.
- Der Fixed-Effects-Parameter  $\beta_f$  parameterisiert dabei explizit der Erwartungswert dieser Population.
- Fixed-Effects-Parameter können also als Populationserwartungswerte interpretiert werden.
- Random-Effects-Parameter dagegen entsprechen Abweichungen vom Populationserwartungswert.
- Wir setzen auch hier die Unabhängigkeit von  $\beta$  und  $\varepsilon$  implizit voraus.

## Beweis

Mit dem Theorem zur linearen Transformation normalverteilter Zufallsvektoren gilt

$$\begin{aligned} & y = X_r \beta + \varepsilon \text{ mit } \beta := X \beta_f + \beta_r, X_f := X_r X \text{ und } \beta \sim N(X \beta_f, \Sigma_{\beta_r}) \text{ und } \varepsilon \sim N(0_n, \Sigma_\varepsilon) \\ \Leftrightarrow & y = X_r \beta + \varepsilon \text{ mit } \beta := X \beta_f + \beta_r, X_f := X_r X \text{ und } \beta_r \sim N(0_q, \Sigma_{\beta_r}) \text{ und } \varepsilon \sim N(0_n, \Sigma_\varepsilon) \\ \Leftrightarrow & y = X_r (X \beta_f + \beta_r) + \varepsilon \text{ mit } X_f := X_r X, \beta_r \sim N(0_q, \Sigma_{\beta_r}) \text{ und } \varepsilon \sim N(0_n, \Sigma_\varepsilon) \\ \Leftrightarrow & y = X_r X \beta_f + X_r \beta_r + \varepsilon \text{ mit } X_f := X_r X, \beta_r \sim N(0_q, \Sigma_{\beta_r}) \text{ und } \varepsilon \sim N(0_n, \Sigma_\varepsilon) \\ \Leftrightarrow & y = X_f \beta_f + X_r \beta_r + \varepsilon \text{ mit } \beta_r \sim N(0_q, \Sigma_{\beta_r}) \text{ und } \varepsilon \sim N(0_n, \Sigma_\varepsilon). \end{aligned} \tag{15}$$

## Beispiel zur Populationsparameterdarstellung des Linear Mixed Models

Für das Random-Effects-Modell der Metaanalyse gilt bekanntlich

$$y_i = \delta_i + \varepsilon_i \text{ mit } \varepsilon_i \sim N(0, \sigma_i^2) \text{ und } \delta_i \sim N(\delta, \tau^2) \text{ für } i = 1, \dots, n \quad (16)$$

und unter der Annahme der paarweisen Unabhängigkeit aller Zufallsvariablen. In Matrixform entspricht das Random-Effects-Modell der Metaanalyse dann zunächst für  $y := (y_1, \dots, y_n)^T$  und  $\tilde{\delta} := (\delta_1, \dots, \delta_n)^T$

$$y = \tilde{\delta} + \varepsilon \text{ mit } \tilde{\delta} \sim N(\mathbf{1}_n \delta, \tau^2 I_n) \text{ und } \varepsilon \sim N(0_n, \text{diag}(\sigma_1^2, \dots, \sigma_n^2)) \quad (17)$$

Mit den Bezeichnungen der Populationsdarstellung des Linear Mixed Models gilt dann äquivalent für

$$\beta := \tilde{\delta}, X := \mathbf{1}_n, \beta_f := \delta, \Sigma_{\beta_r} := \tau^2 I_n \text{ und } \Sigma_\varepsilon := \text{diag}(\sigma_1^2, \dots, \sigma_n^2) \quad (18)$$

die Darstellung

$$y = \beta + \varepsilon \text{ mit } \beta \sim N(X\beta_f, \Sigma_{\beta_r}) \text{ und } \varepsilon \sim N(0_n, \Sigma_\varepsilon). \quad (19)$$

Offenbar gilt hier also  $X_r := I_n$  und es folgt die Linear Mixed Model Darstellung

$$y = X_r X \beta_f + X_r \beta_r + \varepsilon \text{ mit } \beta_r \sim N(0_n, \Sigma_{\beta_r}) \text{ und } \varepsilon \sim N(0_n, \Sigma_\varepsilon). \quad (20)$$

also

$$y = \mathbf{1}_n \beta_f + \beta_r + \varepsilon \text{ mit } \beta_r \sim N(0_n, \Sigma_{\beta_r}) \text{ und } \varepsilon \sim N(0_n, \Sigma_\varepsilon). \quad (21)$$

# Modellformulierung

## Überblick zur Modellschätzung

Wie bereits gesehen, impliziert das Linear Mixed Model mit

$$\Sigma_{\beta_r} := \sigma_{\beta_r}^2 I_q \text{ und } \Sigma_{\varepsilon} := \sigma_{\varepsilon}^2 I_n \quad (22)$$

die gemeinsame Verteilung von Datenvektor und Random-Effects-Vektor

$$\begin{pmatrix} \beta_r \\ y \end{pmatrix} \sim N \left( \begin{pmatrix} 0_q \\ X_f \beta_f \end{pmatrix}, \begin{pmatrix} \sigma_{\beta_r}^2 I_q & \sigma_{\beta_r}^2 X_r^T \\ \sigma_{\beta_r}^2 X_r & \sigma_{\beta_r}^2 X_r X_r^T + \sigma_{\varepsilon}^2 I_n \end{pmatrix} \right), \quad (23)$$

sowie die marginale Datenverteilung

$$y \sim N \left( X_f \beta_f, \sigma_{\beta_r}^2 X_r X_r^T + \sigma_{\varepsilon}^2 I_n \right). \quad (24)$$

Mithilfe der Definitionen des *Varianzkomponentenvektors*  $\theta$  und des marginalen Datenkovarianzmatrixparameters  $V_{\theta}$

$$\theta := \left( \sigma_{\beta_r}^2, \sigma_{\varepsilon}^2 \right) \text{ und } V_{\theta} := \sigma_{\beta_r}^2 X_r X_r^T + \sigma_{\varepsilon}^2 I_n, \quad (25)$$

wird die marginale Datenverteilung des Linear Mixed Models häufig auch als

$$y \sim N \left( X_f \beta_f, V_{\theta} \right) \quad (26)$$

geschrieben. Das Schätzproblem für ein Linear Mixed Model hat dann drei zentrale Aspekte:

- (1) Die Angabe eines Schätzers  $\hat{\beta}_f$  für den Fixed-Effects-Parameter  $\beta_f$ .
- (2) Die Angabe eines Schätzers  $\hat{\theta}$  für den Varianzkomponentenparameter  $\theta$ .
- (3) Die Angabe eines Schätzers  $\hat{\beta}_r$  für den Random-Effects-Parameter  $\beta_r$ .



## Überblick zur Modellschätzung

Die Lösung dieses Problems ist nicht trivial und Gegenstand aktueller Forschung.

Generell werden in der Anwendung iterative Verfahren genutzt und meist folgende Ansätze verfolgt:

(1) Schätzung von  $\beta_f$  basierend auf der geschätzten Marginalverteilung von  $y$

⇒  $V_\theta$  wird durch  $V_{\hat{\theta}}$  ersetzt und  $\beta_f$  durch den *Generalisierten-Kleinste-Quadrate Schätzer* geschätzt.

(2) Schätzung von  $\theta$  basierend auf der geschätzten Marginalverteilung von  $y$

⇒  $\theta$  wird iterativ mit dem *Restricted Maximum-Likelihood* Verfahren geschätzt.

(3) Schätzung von  $\beta_r$  basierend auf der geschätzten gemeinsamen Verteilung von  $\beta_r$  und  $y$

⇒  $V_\theta, \beta_f$  werden durch  $V_{\hat{\theta}}, \hat{\beta}_f$  ersetzt und  $\beta_r$  durch seinen *bedingten Erwartungswert* geschätzt.

## Überblick zur Modellschätzung

Iteratives Verfahren zur Schätzung der Parameter eines Linear Mixed Models

(0) Initialisierung

- Wahl eines geeigneten Startwerts  $\hat{\beta}_f^{(0)}$

(1) Für  $k = 1, \dots, K$

- ReML-Schätzung  $\hat{\theta}^{(k)}$  basierend auf  $\hat{\beta}_f^{(k-1)}$
- GLS-Schätzung  $\hat{\beta}_f^{(k)}$  basierend auf  $\hat{\theta}^{(k)}$

(2) Schätzung von  $\hat{\beta}_r$  basierend auf  $\hat{\theta}^{(K)}$  und  $\hat{\theta}^{(K)}$

---

Modellformulierung

**Generalisierte Kleinste-Quadrate Schätzung der Fixed-Effects**

Varianzkomponentenschätzung mit Restricted Maximum-Likelihood

Bedingter Erwartungswert der Random-Effects

Selbstkontrollfragen

# Generalisierte Kleinste-Quadrate Schätzung der Fixed-Effects

## Generalisierte Kleinste-Quadrate Schätzung

- Kleinste-Quadrate Schätzung heißt auf English “Ordinary Least Squares” (OLS).
- Zur Abgrenzung nennen wir den bekannten Betaparameterschätzer im Folgenden “OLS-Schätzer”.
- Generalisierte Kleinste-Quadrate Schätzung heißt auf English “Generalized Least Squares” (GLS).
- Der GLS-Schätzer ist ein Betaparameterschätzer für das ALM

$$y = X\beta + \varepsilon \text{ mit } \varepsilon \sim N(0_n, \sigma^2 V) \text{ mit } V \neq I_n \quad (27)$$

- Der GLS-Schätzer ist also im Fall nicht-sphärischer Fehlerkovarianzmatrixparameter angezeigt.
- Der GLS-Schätzer stellt sicher, dass  $T$ -Statistiken auch im Fall  $V \neq I_n$   $t$ -verteilt sind.
- Im Kontext der Fixed-Effects-Schätzung eines Linear Mixed Models gilt in Hinblick auf obiges ALM speziell

$$X := X_f, \beta := \beta_f, \sigma^2 := \sigma_\varepsilon^2 \sigma_{\beta_r}^2, V := \frac{1}{\sigma_\varepsilon^2} X_r X_r^T + \frac{1}{\sigma_{\beta_r}^2} I_n \text{ und somit } \sigma^2 V = V_\theta. \quad (28)$$

## Definition (Generalisierte Kleinste-Quadrate Schätzer)

Gegeben sei ein Allgemeines Lineares Modell der Form

$$y = X\beta + \varepsilon \text{ mit } \varepsilon \sim N(0_n, \sigma^2 V) \text{ mit} \quad (29)$$

mit  $\sigma^2 > 0$  und einer positiv-definiten Matrix  $V \in \mathbb{R}^{n \times n}$ . Dann heißt

$$\hat{\beta}_{\text{GLS}} := (X^T V^{-1} X)^{-1} X^T V^{-1} y \quad (30)$$

der *Generalisierte-Kleinste-Quadrate-Schätzer* von  $\beta$  und

$$\hat{\sigma}_{\text{GLS}}^2 := \frac{(y - X\hat{\beta}_{\text{GLS}})^T V^{-1} (y - X\hat{\beta}_{\text{GLS}})}{n - p} \quad (31)$$

der *Generalisierte-Kleinste-Quadrate-Schätzer* von  $\sigma^2$ .

### Bemerkungen

- Es muss nicht notwendigerweise  $V = I_n$  gelten.
- Die Fehlerkomponenten in  $\varepsilon$  können unterschiedliche Varianzen haben oder korreliert sein.
- Im Fall  $V = I_n$  gilt weiterhin

$$\hat{\beta}_{\text{GLS}} = (X^T I_n^{-1} X)^{-1} X^T I_n^{-1} y = (X^T X)^{-1} X^T y =: \hat{\beta}_{\text{OLS}}. \quad (32)$$

## Theorem (GLS-Schätzer und OLS-Schätzer)

Gegeben sei ein *untransformiertes ALM* der Form

$$y = X\beta + \varepsilon \text{ mit } \varepsilon \sim N(0_n, \sigma^2 V) \quad (33)$$

mit  $\sigma^2 > 0$  und einer positiv-definiten Matrix  $V \in \mathbb{R}^{n \times n}$  und es sei  $\hat{\beta}_{\text{GLS}}$  der Generalisierte-Kleinste-Quadrate-Schätzer von  $\beta$ . Weiterhin sei  $K \in \mathbb{R}^{n \times n}$  eine Matrix mit den Eigenschaften

$$KK^T = V \text{ und } (K^{-1})^T K^{-1} = V^{-1} \quad (34)$$

Schließlich sei

$$y^* = X^* \beta + \varepsilon^* \text{ mit } y^* := K^{-1}y, X^* := K^{-1}X, \varepsilon^* := K^{-1}\varepsilon \quad (35)$$

das *transformierte ALM*. Dann gelten

- (1) Der GLS-Schätzer des untransformierten ALMs ist der OLS-Schätzer des transformierten ALMs.
- (2) Für den Zufallsfehler im transformierten ALM gilt  $\varepsilon^* \sim N(0_n, \sigma^2 I_n)$ .

### Bemerkungen

- Der zu schätzende wahre, aber unbekannt, Betaparameter ist in beiden ALMs identisch.
- Im transformierten ALM ist der Fehlerkovarianzmatrixparameter sphärisch, also  $T$ -Statistiken  $t$ -verteilt.
- Man nennt die Transformation des ALMs durch  $K$  auch eine "Whitening-Transformation".
- $K$  mit den geforderten Eigenschaften kann durch die *Cholesky-Zerlegung* von  $V$  gewonnen werden.

# Generalisierte Kleinste-Quadrate Schätzung der Fixed-Effects

## Beweis

(1) Für den GLS-Schätzer im untransformierten Modell gilt

$$\begin{aligned}\hat{\beta}_{\text{GLS}} &= (X^T V^{-1} X)^{-1} X^T V^{-1} y \\ &= \left( X^T (K^{-1})^T K^{-1} X \right)^{-1} X^T (K^{-1})^T K^{-1} y \\ &= \left( (K^{-1} X)^T K^{-1} X \right)^{-1} (K^{-1} X)^T K^{-1} y \\ &= \left( X^{*T} X^* \right)^{-1} X^{*T} y^*.\end{aligned}\tag{36}$$

Dies aber entspricht dem OLS-Schätzer im transformierten Modell.

(2) Mit der Tatsache, dass für eine invertierbare Matrix  $A$  immer gilt, dass  $(A^{-1})^T = (A^T)^{-1}$  und dem Theorem zur linear-affinen Transformation multivariater Normalverteilungen ergibt sich

$$\begin{aligned}\varepsilon^* &\sim N\left(K^{-1} 0_n, K^{-1} (\sigma^2 V) K^{-1T}\right) \\ &= N\left(0_n, \sigma^2 K^{-1} V K^{-1T}\right) \\ &= N\left(0_n, \sigma^2 K^{-1} K K^T K^{-1T}\right) \\ &= N\left(0_n, \sigma^2 K^{-1} K K^T K^{T^{-1}}\right) \\ &= N\left(0_n, \sigma^2 I_n\right).\end{aligned}\tag{37}$$

□

## Definition (Fixed-Effects-Parameterschätzer)

Gegeben sei die marginale Datenverteilung eines Linear Mixed Models mit einem Schätzer  $\hat{\theta}$  für  $\theta$ , also

$$y \sim N(X_f \beta_f, V_{\hat{\theta}}). \quad (38)$$

Dann ist der GLS-Schätzer in diesem Modell

$$\hat{\beta}_f = \left( X_f^T V_{\hat{\theta}}^{-1} X_f \right)^{-1} X_f^T V_{\hat{\theta}}^{-1} y \quad (39)$$

ein populärer Schätzer für den Fixed-Effects-Parameter  $\beta_f$  des Linear Mixed Models.

```
gls = function(y, X, V){  
  # Diese Funktion bestimmt den generalisierten Kleinste-Quadrate-Schätzer.  
  #  
  # Inputs  
  # y      : y x 1 Datenvektor  
  # X      : n x p Designmatrix  
  # V      : n x n marginale Datenkovarianzmatrix  
  #  
  # Outputs  
  # beta_hat : p x 1 generalisierter Kleinste-Quadrate-Schätzer  
  # -----  
  Vi      = solve(V) # Inverse  
  beta_hat = solve(t(X) %*% Vi %*% X) %*% t(X) %*% Vi %*% y # GKQ Schätzer  
  return(beta_hat) # Output  
}
```



---

Modellformulierung

Generalisierte Kleinste-Quadrate Schätzung der Fixed-Effects

**Varianzkomponentenschätzung mit Restricted Maximum-Likelihood**

Bedingter Erwartungswert der Random-Effects

Selbstkontrollfragen

# Varianzkomponentenschätzung mit Restricted Maximum-Likelihood

## Motivation

Die Maximum-Likelihood Methode kann auf verzerrte Varianzschätzer führen

Zum Beispiel ist der Maximum-Likelihood-Schätzer des Varianzparameters des Normalverteilungsmodells

$$\hat{\sigma}_{\text{ML}}^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{\mu}_{\text{ML}})^2 \quad \text{mit} \quad \hat{\mu}_{\text{ML}} := \frac{1}{n} \sum_{i=1}^n y_i =: \bar{y}. \quad (40)$$

verzerrt und nur asymptotisch erwartungstreu. Speziell gilt mit der Erwartungstreue der Stichprobenvarianz

$$\mathbb{E}(\hat{\sigma}^2) = \mathbb{E}\left(\frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2\right) = \frac{1}{n-1} \mathbb{E}\left(\sum_{i=1}^n (y_i - \bar{y})^2\right) = \sigma^2, \quad (41)$$

dass

$$\mathbb{E}(\hat{\sigma}_{\text{ML}}^2) = \mathbb{E}\left(\frac{1}{n} \sum_{i=1}^n (y_i - \hat{\mu}_{\text{ML}})^2\right) = \frac{1}{n} \mathbb{E}\left(\sum_{i=1}^n (y_i - \bar{y}_n)^2\right) = \frac{n-1}{n} \sigma^2 \quad (42)$$

Da  $(n-1)/n < 1$  insbesondere bei kleinem  $n$ , unterschätzt der Maximum-Likelihood-Schätzer  $\sigma^2$ .

Patterson and Thompson (1971) schreiben "The difference between the two methods [ML und ReML] is analogous to the well-known difference between two methods of estimating the variance  $\sigma^2$  of a normal distribution [wie oben] (...)" und Harville (1977) merkt an "One criticism of the ML approach to the estimation of  $[\sigma^2]$  is that the ML estimator (...) takes no account of the loss in degrees of freedom that results from estimating  $[\mu]$  (...) These "deficiencies" are eliminated in the restricted Maximum-Likelihood (REML) approach (...)"

⇒ ReML für Varianzparameterschätzung scheint eine gute Idee zu sein.

# Varianzkomponentenschätzung mit Restricted Maximum-Likelihood

---

## Zentrale Referenzen zur Theorie der Restricted Maximum-Likelihood Schätzung

Patterson and Thompson (1971)

- Fehlerkontrastmotivation der Restricted Maximum-Likelihood Zielfunktion

Harville (1977)

- Übersicht zu Restricted Maximum-Likelihood Methoden und numerischer Auswertung

Searle, Casella, and McCulloch (1992)

- Ausführliche Übersicht zum Problem der Varianzkomponentenschätzung

Bates and DebRoy (2004)

- Integration von Restricted Maximum-Likelihood in Penalized Least Squares

Starke and Ostwald (2017)

- Expectation-Maximization und Restricted Maximum-Likelihood aus der Perspektive von Variational Inference

# Varianzkomponentenschätzung mit Restricted Maximum-Likelihood

## Maximum-Likelihood und Restricted Maximum-Likelihood

Betrachtet man die marginale Datenverteilung des Linear Mixed Models

$$y \sim N(X_f \beta_f, V_\theta) \quad (43)$$

so ergibt sich für die Log-Likelihood Funktion der Varianzkomponenten  $\theta$  für einen Schätzer  $\hat{\beta}_f$  von  $\beta_f$

$$\begin{aligned} \ell(\theta) &= \ln \left( (2\pi)^{-\frac{n}{2}} |V_\theta|^{-\frac{1}{2}} \exp \left( -\frac{1}{2} (y - X_f \hat{\beta}_f)^T V_\theta^{-1} (y - X_f \hat{\beta}_f) \right) \right) \\ &= -\frac{n}{2} \ln 2\pi - \frac{1}{2} \ln |V_\theta| - \frac{1}{2} (y - X_f \hat{\beta}_f)^T V_\theta^{-1} (y - X_f \hat{\beta}_f) \end{aligned} \quad (44)$$

Die (numerische) Maximierung dieser Funktion hinsichtlich  $\theta$  führt zu einem Maximum-Likelihood-Schätzer von  $\theta$ ,

$$\hat{\theta}_{\text{ML}} := \operatorname{argmax}_\theta \left( -\frac{1}{2} \ln |V_\theta| - \frac{1}{2} (y - X_f \hat{\beta}_f)^T V_\theta^{-1} (y - X_f \hat{\beta}_f) \right). \quad (45)$$

Ein zentrales Resultat ist, dass ein Restricted Maximum-Likelihood-Schätzer von  $\theta$  gegeben ist durch

$$\hat{\theta}_{\text{ReML}} := \operatorname{argmax}_\theta \left( -\frac{1}{2} \ln |V_\theta| - \frac{1}{2} \ln |X_f^T V_\theta^{-1} X_f| - \frac{1}{2} (y - X_f \hat{\beta}_f)^T V_\theta^{-1} (y - X_f \hat{\beta}_f) \right). \quad (46)$$

Die Zielfunktion der ReML Methode und der ML Methode unterscheiden sich also nur hinsichtlich eines Terms.

Im Folgenden wollen wir die Motivation für die Einführung des Terms  $-\frac{1}{2} \ln |X_f^T V_\theta^{-1} X_f|$  (sehr) grob skizzieren.

# Varianzkomponentenschätzung mit Restricted Maximum-Likelihood

Motivation der Restricted Maximum-Likelihood Funktion durch Fehlerkontraste

Grundidee des von Patterson and Thompson (1971) formulierten Ansatzes ist es, den Effekt von  $\beta_f$  aus  $y$  herauszurechnen und dann die Likelihood-Funktion der so transformierten Daten hinsichtlich von  $\theta$  zu maximieren.

Genauer ist das Ziel den Datenvektor durch eine lineare Transformation mit einer Matrix  $M \in \mathbb{R}^{m \times n}$  in einen anderen Vektor  $z$  zu transformieren, dessen Erwartungswert für jeden möglichen Wert von  $\beta_f$  der Nullvektor ist, also

$$z = My \text{ mit } \mathbb{E}(z) = 0_m \text{ für alle } \beta_f \in \mathbb{R}^p \quad (47)$$

und dann die Log-Likelihood-Funktion von  $z$  zu maximieren.

Eine solche Matrix  $M$  muss insbesondere die Bedingung

$$MX_f = 0_m \quad (48)$$

erfüllen, denn dann gilt

$$\mathbb{E}(z) = \mathbb{E}(My) = \mathbb{E}(MX_f\beta_f) = \mathbb{E}(0_m\beta_f) = 0_m \text{ für alle } \beta_f \in \mathbb{R}^p. \quad (49)$$

Eine prinzipielle Möglichkeit für die Wahl von  $M$  ist die  $n \times n$  Matrix

$$M = I_n - P_n \text{ mit } P_n := X_f(X_f^T X_f)^{-1} X_f^T \in \mathbb{R}^{n \times n} \quad (50)$$

mit der sogenannten *Projektionsmatrix*  $P$ .

# Varianzkomponentenschätzung mit Restricted Maximum-Likelihood

Motivation der Restricted Maximum-Likelihood Funktion durch Fehlerkontraste

Es gilt dann nämlich

$$MX_f = (I_n - P_n)X_f = X_f - P_n X_f = X_f - X_f(X_f^T X_f)^{-1} X_f^T X_f = X_f - X_f = 0_{nn}. \quad (51)$$

Nutzt man also diese Matrix  $M$  zur Transformation der Daten, ergibt sich

$$z = My = (I_n - P_n)y = y - X_f(X_f^T X_f)^{-1} X_f^T y = y - X_f \hat{\beta}_f = \hat{\varepsilon} \quad (52)$$

und wir sehen, dass eine solche Matrix  $M$  die Daten auf die Residuals, also die Differenz zwischen Daten und Modellvorhersage nach Schätzung der Fixed-Effects projiziert. Die Matrix  $P_n$  nennt man dementsprechend auch *Residual-forming matrix* oder *Projektionsmatrix* und die Matrix  $M$  *Fehlerkontrastmatrix*. Der Vektor  $z$  sind dann die Residuals und ReML wird auch häufig als *Residual Maximum-Likelihood* bezeichnet. Eine Zeile einer solchen Matrix  $M$  nennt man auch *Fehlerkontrast*, die Matrix  $M$  daher eine *Fehlerkontrastmatrix*.

Prinzipiell würde man nun die Log-Likelihood Funktion von  $z \in \mathbb{R}^n$ , das aufgrund des Theorems zur linear-affinen Transformation multivariater Normalverteilungen die Verteilung

$$z \sim N(MX\beta_f, MV_\theta M^T) \quad (53)$$

hat, also

$$\ell(\theta) = \frac{n}{2} \ln 2\pi - \frac{1}{2} \ln |MV_\theta M^T| - \frac{1}{2} (My)^T (MV_\theta M^T)^{-1} My. \quad (54)$$

# Varianzkomponentenschätzung mit Restricted Maximum-Likelihood

Motivation der Restricted Maximum-Likelihood Funktion durch Fehlerkontraste

Leider funktioniert die vorgeschlagene Wahl von  $M$  in dieser Form nicht, "da  $\text{rg}(M) = m < n$ ".

Man wählt daher die ersten  $n-p$  Zeilen von  $M$  und erhält eine Matrix  $K \in \mathbb{R}^{m \times n}$  mit vollem Spaltenrang  $m = n-p$ .

Dabei gilt weiterhin  $\mathbb{E}(z) = \mathbb{E}(Ky) = 0_m$  und man möchte

$$\ell(\theta) = \frac{m}{2} \ln 2\pi - \frac{1}{2} \ln |KV_\theta K^T| - \frac{1}{2} (Ky)^T (KV_\theta K^T)^{-1} Ky \quad (55)$$

maximieren.

Searle, Casella, and McCulloch (1992) beweisen nun, dass

$$\ln |KV_\theta K^T| = \ln |V_\theta| + \ln |X_f V_\theta^{-1} X_f| \quad (56)$$

und

$$(Ky)^T (KV_\theta K^T)^{-1} Ky = y^T P_n y = (y - X_f \hat{\beta}_f)^T V_\theta^{-1} (y - X_f \hat{\beta}_f) \quad (57)$$

Dies ist intuitiv zumindest unter dem Aspekt, dass  $K$  Teil von  $P_n$  ist, einsichtig. Damit ergibt sich für die Log-Likelihood-Funktion von  $z = Ky$  aber, dass

$$\ell(\theta) = \frac{m}{2} \ln 2\pi - \frac{1}{2} \ln |V_\theta| - \frac{1}{2} \ln |X_f V_\theta^{-1} X_f| - \frac{1}{2} (y - X_f \hat{\beta}_f)^T V_\theta^{-1} (y - X_f \hat{\beta}_f) \quad (58)$$

also identisch mit der ReML Zielfunktion ist.

# Varianzkomponentenschätzung mit Restricted Maximum-Likelihood

---

Die hier gegebene Darstellung lässt allerdings viele Fragen offen

- Warum sind ReML Schätzer der Varianzkomponenten unverzerrt (vgl. Foulley (1993))?
- Was sind weitere generelle Eigenschaften der ReML Schätzer (vgl. Harville (1977))
- Was genau ist das Problem bei Residualprojektion mit  $M = (I_n - P_n)$ ?
- Wie und wann funktionieren die Beweise von Searle, Casella, and McCulloch (1992)?

Darüber hinaus ergeben sich zumindest folgende Fragen

- Was verhält sich die Fehlerkontrastmotivation zur Expectation-Maximization Motivation (vgl. Laird (1982))?
- Wie verhält sich die Fehlerkontrastmotivation zur bedingten Verteilungsmotivation (vgl. Verbyla (1990))?
- Welche Algorithmen eignen sich zur Maximierung der ReML Zielfunktion (vgl. Lindstrom and Bates (1990))?
- Wie verhalten sich ReML und Penalized-Least-Squares (vgl. Bates and DebRoy (2004))?



# Varianzkomponentenschätzung mit Restricted Maximum-Likelihood

## Definition (ReML-Varianzkomponentenschätzer)

Gegeben sei die marginale Datenverteilung eines Linear Mixed Models basierend auf einem Fixed-Effects-Parameterschätzer  $\hat{\beta}_f$ , also

$$y \sim N(X_f \hat{\beta}_f, V_\theta) \quad (59)$$

Dann ist der ReML Schätzer in diesem Modell,

$$\hat{\theta}_{\text{ReML}} := \operatorname{argmax}_\theta \left( -\frac{1}{2} \ln |V_\theta| - \frac{1}{2} \ln |X_f^T V_\theta^{-1} X_f| - \frac{1}{2} (y - X_f \hat{\beta}_f)^T V_\theta^{-1} (y - X_f \hat{\beta}_f) \right), \quad (60)$$

ein populärer Schätzer für den Varianzkomponentenvektor  $\theta$ .

```
llh_reml = function(theta, y, X_f, X_r, beta_f_hat, Sigma_eps){
  # Diese Funktion evaluiert die negative restricted log likelihood
  # Zielfunktion für das Random-Effects-Modell der Metaanalyse.
  #
  # Inputs
  # theta      : k x 1 Varianzkomponentenvektor
  # y          : n x 1 Datenvektor
  # X_f        : n x p Fixed-Effects-Designmatrix
  # X_r        : n x q Random-Effects-Designmatrix
  # beta_f_hat : p x 1 Fixed-Effects Schätzer
  #
  # Outputs
  # llh_reml   : 1 x 1 Wert der ReML Zielfunktion
  # -----
  n      = nrow(X_r)                # Datenpunktzahl
  V      = theta[1]*X_r %>% t(X_r) + theta[2]*diag(n) # marginale Datenkovarianzmatrix
  Vi     = solve(V)                 # Inverse
  R      = y - X_f %>% beta_f_hat    # Residuals
  T1     = -(1/2)*log(det(V))        # Erster Term
  T2     = -(1/2)*log(det(t(X_f) %>% Vi %>% X_f)) # Zweiter Term
  T3     = -(1/2)*t(R) %>% Vi %>% R  # Dritter Term
  llh_reml = T1 + T2 + T3           # Restricted Log Likelihood
  return(llh_reml)}                # Wert der ReML Zielfunktion
```

# Varianzkomponentenschätzung mit Restricted Maximum-Likelihood

## Hilfsfunktionen zur ReML-Zielfunktionoptimierung

```
reml = function(theta, lmm){
  # Diese Funktion ist eine Wrapperfunktion für l_reml() zum Gebrauch mit
  # der generischen R Optimierungsfunktion optim().
  #
  # Inputs
  # theta : k x 1 Varianzkomponentenvektor
  # lmm   : Liste von LMM Komponenten
  #
  # Output
  # reml  : Wert der restricted log likelihood Funktion
  # -----
  y      = lmm$y                # Datenvektor
  X_f    = lmm$X_f              # Fixed-Effects-Designmatrix
  X_r    = lmm$X_r              # Random-Effects-Designmatrix
  beta_f_hat = lmm$beta_f_hat   # Fixed-Effects Schätzer
  l_reml = llh_reml(theta,y,X_f,X_r,beta_f_hat) # Wert der ReML Zielfunktion
  return(-l_reml)}             # Ausgabeargument

mcov = function(theta, X_r){
  # Diese Funktion schätzt generierte eine marginale Datenkovarianzmatrix
  # basierend auf einer Random-Effects-Designmatrix und der Varianzkomponenten.
  #
  # Inputs:
  # theta : c x 1 Varianzkomponentenvektor
  # X_r   : n x q Random-Effects-Designmatrix
  #
  # Outputs
  # V_theta : n x n marginale Kovarianzmatrix
  # -----
  V_theta = theta[1]*(X_r%*%t(X_r)) + theta[2]*diag(nrow(X_r)) # marginale Datenkovarianzmatrix
  return(V_theta)}                                             # Ausgabeargument
```

---

Modellformulierung

Generalisierte Kleinste-Quadrate Schätzung der Fixed-Effects

Varianzkomponentenschätzung mit Restricted Maximum-Likelihood

**Bedingter Erwartungswert der Random-Effects**

Selbstkontrollfragen

# Bedingter Erwartungswert der Random Effects

Das Linear Mixed Model impliziert wie gesehen eine gemeinsame Verteilung von Daten und unbeobachtbarem Random-Effects-Vektor  $\beta_r$ . Ein Standardvorgehen im Bereich der Linear Mixed Model Schätzung ist es,  $\beta_r$  durch den Erwartungswert der auf den Daten bedingten Verteilung von  $\beta_r$  zu schätzen, wobei unbekannte Parameterwerte wiederum durch ihre Schätzer ersetzt werden.

Dieses Vorgehen entspricht damit letztlich einer Bayesianischen Punktschätzung von  $\beta_r$  mit marginaler Verteilung ("Prior distribution")

$$\beta_r \sim N\left(0_q, \hat{\sigma}_{\beta_r}^2 I_q\right) \quad (61)$$

und bedingter Verteilung ("Likelihood")

$$y | \beta_r \sim N\left(X_f \hat{\beta}_f + X_r \beta_r, \hat{\sigma}_\varepsilon^2 I_n\right) \quad (62)$$

Anwendung des Theorems zur bedingten Normalverteilungen auf die hier relevante gemeinsame Verteilung

$$\begin{pmatrix} \beta_r \\ y \end{pmatrix} \sim N\left(\begin{pmatrix} 0_q \\ X_f \hat{\beta}_f \end{pmatrix}, \begin{pmatrix} \hat{\sigma}_{\beta_r}^2 I_q & \hat{\sigma}_{\beta_r}^2 X_r^T \\ \hat{\sigma}_{\beta_r}^2 X_r & V_{\hat{\theta}} \end{pmatrix}\right) \quad (63)$$

ergibt dann als Schätzer für den Random-Effects Parameter den Erwartungswertparameter der Verteilung  $\beta_r | y$

$$\hat{\beta}_r = \mu_{\beta_r | y} = \hat{\sigma}_{\beta_r}^2 X_r^T V_{\hat{\theta}}^{-1} (y - X_f \hat{\beta}_f). \quad (64)$$

## Definition (Random-Effects-Parameterschätzer)

Gegeben sei die gemeinsame Verteilung von Random-Effects und Daten eines Linear Mixed Models basierend auf einem Fixed-Effects-Parameterschätzer  $\hat{\beta}_f$  und einem Varianzkomponentenschätzer  $\hat{\theta} := \left( \hat{\sigma}_{\beta_r}^2, \widehat{\text{sigma}}_{\varepsilon}^2 \right)$ , also

$$\begin{pmatrix} \beta_r \\ y \end{pmatrix} \sim N \left( \begin{pmatrix} 0_q \\ X_f \hat{\beta}_f \end{pmatrix}, \begin{pmatrix} \hat{\sigma}_{\beta_r}^2 I_q & \hat{\sigma}_{\beta_r}^2 X_r^T \\ \hat{\sigma}_{\beta_r}^2 X_r & V_{\hat{\theta}} \end{pmatrix} \right). \quad (65)$$

Dann ist bedingte Erwartungswert von  $\beta_r$  in diesem Modell, also

$$\hat{\beta}_r = \mu_{\beta_r|y} = \hat{\sigma}_{\beta_r}^2 X_r^T V_{\hat{\theta}}^{-1} (y - X_f \hat{\beta}_f). \quad (66)$$

ein populärer Schätzer für den Random-Effects-Parameter.

# Bedingter Erwartungswert der Random Effects

```
rfx = function(lmm){
  # Diese Funktion bestimmt den bedingten Erwartungswert der Random-Effects
  # Inputs :
  #   lmm   : R Liste mit Einträgen
  #   $y     : n x 1 Datenvektor
  #   $X_f   : n x p Fixed-Effects-Designmatrix
  #   $X_r   : n x q Random-Effects-Designmatrix
  #   $beta_f_hat : p x 1 Fixed-Effects-Parameterschätzer
  #   $s_beta_r_hat : 1 x 1 Random-Effects-Varianzkomponente
  #   $s_eps_hat  : 1 x 1 Fehler-Varianzkomponente
  # Outputs :
  #   lmm     : R Liste mit zusätzlichen Einträgen
  #   $beta_r_hat : q x 1 Random-Effects-Parameterschätzer
  # -----
  y           = lmm$y           # Daten
  X_r        = lmm$X_r         # Random-Effects-Designmatrix
  X_f        = lmm$X_f         # Fixed-Effects-Designmatrix
  beta_f_hat = lmm$beta_f_hat  # Fixed-Effects-Parameterschätzer
  s_beta_r_hat = lmm$s_beta_r_hat # Random-Effects-Varianzkomponentenschätzer
  s_eps_hat  = lmm$s_eps_hat   # Fehlervarianzkomponentenschätzer
  theta_hat  = c(s_beta_r_hat,s_eps_hat) # Varianzkomponentenschätzer
  V_theta_hat_i = solve(mcov(theta_hat, X_r)) # Inverser Datenkovarianzmatrixschätzer
  eps_hat    = (y - X_f %*% beta_f_hat) # Residuals
  lmm$beta_r_hat = s_beta_r_hat*t(X_r) %*% V_theta_hat_i %*% eps_hat} # Random-Effects-Parameterschätzer
```

## Iteratives Verfahren zur Schätzung der Parameter eines Linear Mixed Models

### (0) Initialisierung

- Wahl eines geeigneten Startwerts  $\hat{\beta}_f^{(0)}$

### (1) Für $k = 1, \dots, K$

- ReML-Schätzung  $\hat{\theta}^{(k)}$  basierend auf  $\hat{\beta}_f^{(k-1)}$
- GLS-Schätzung  $\hat{\beta}_f^{(k)}$  basierend auf  $\hat{\theta}^{(k)}$

### (2) Schätzung von $\hat{\beta}_r$ basierend auf $\hat{\theta}^{(K)}$ und $\hat{\theta}^{(K)}$

# Modellschätzung

## Iteratives Verfahren zur Schätzung der Parameter eines Linear Mixed Models

```
estimate = function(lmm){
  # Diese Funktion schätzt die Parameter eines Linear Mixed Models.
  # Inputs :
  #   lmm   : R Liste mit Einträgen
  #   $y     : n x 1 Datenvektor
  #   $X_f   : n x p Fixed-Effects-Designmatrix
  #   $X_r   : n x q Random-Effects-Designmatrix
  #   $c     : 1 x 1 Varianzkomponentenanzahl
  # Outputs :
  #   lmm   : R Liste mit zusätzlichen Einträgen
  #   $beta_f_hat : p x 1 Fixed-Effects-Parameterschätzer
  #   $s_beta_r_hat : 1 x 1 Random-Effects-Varianzschätzer
  #   $s_eps_hat : 1 x 1 Datenvarianzschätzer
  # -----
  y           = lmm$y                # Datenvektor
  X_f        = lmm$X_f              # Fixed-Effects-Designmatrix
  X_r        = lmm$X_r              # Random-Effects-Designmatrix
  c          = lmm$c                # Anzahl Varianzkomponenten
  n          = nrow(X_f)            # Anzahl Datenpunkte
  p          = ncol(X_f)            # Anzahl Fixed-Effects
  q          = ncol(X_r)            # Anzahl Random-Effects
  K          = 2^3                  # maximale Iterationsanzahl
  theta_hat_k = matrix(rep(NaN, c*K), nrow = c) # Varianzkomponentenschätzerarray
  theta_hat_k[,1] = rep(1,c)        # Initialisierung
  beta_f_hat_k = matrix(rep(NaN, p*K), nrow = p) # Fixed-Effects-Schätzerarray
  V_theta_hat_k = mcov(theta_hat_k[,1], X_r)    # marginale Datenkovarianzmatrix
  beta_f_hat_k[,1] = gls(y,X_f,V_theta_hat_k)   # Fixed-Effects-Parameterschätzer
  for (k in 2:K){
    lmm$beta_f_hat = beta_f_hat_k[, k-1]        # Fixed-Effects-Schätzer k-1
    lmm$max_l_reml = optim(par=theta_hat_k[,k-1],fn=reml,lmm=lmm) # ReML-Varianzkomponentenschätzung
    lmm$theta_hat_k[,k] = max_l_reml$par        # Varianzkomponentenschätzer k
    lmm$V_theta_hat_k[,k] = mcov(theta_hat_k[,k], X_r) # marginale Datenkovarianzmatrix
    lmm$beta_f_hat[,k] = gls(y,X_f,V_theta_hat_k)} # Fixed-Effects-Parameterschätzer
  lmm$s_beta_r_hat = beta_f_hat_k[,K]          # Fixed-Effects-Parameterschätzer
  lmm$s_eps_hat    = theta_hat_k[1,K]         # Random-Effects-Varianzkomponente
  lmm$beta_r_hat   = theta_hat_k[2,K]         # Fehler-Varianzkomponente
  lmm$beta_r_hat   = rfx(lmm)                 # Random-Effects-Parameterschätzer
  return(lmm)}                               # Ausgabe
```



## Iteratives Verfahren zur Schätzung der Parameter eines Linear Mixed Models

```
library(Matrix)
D = read.csv("./5_Daten/BDI.csv")
n = nrow(D)
k = 4
n_i = n/k
x = matrix(rep(NA,n), ncol = k)
for(i in 1:k){
  x[,i] = D$ATS[D$HSA == i]}
Xi = array(rep(NA,n*2), dim = c (n_i,2,k))
for(i in 1:k){
  Xi[,,i] = matrix(c(rep(1,n_i),x[,i]), ncol = 2)}
X_f = rbind(Xi[,,1],Xi[,,2],Xi[,,3],Xi[,,4])
X_r = as.matrix(bdiag(Xi[,,1],Xi[,,2],Xi[,,3],Xi[,,4]))
y = D$BDI
lmm = list(y = y, X_f = X_f, X_r = X_r, c = 2)
lmm = estimate(lmm)


# Blockdiagonalmatrizen
# Dateneinlesen
# Anzahl Datenpunkte
# Anzahl Zentren
# Anzahl Datenpunkte pro Zentrum
# Therapiedauerarray
# Zentreniterationen
# Anzahl Therapiestunden pro Zentrum
# Zentrumspezifische Regressionsmatrizenarray
# Zentreniterationen
# Zentrumspezifische Regressionmatrix
# Fixed-Effects-Designmatrix
# Random-Effects-Designmatrix
# Daten
# LMM Komponenten
# Modellschätzung
```

```
beta_f_hat      : 3.37 1.17
beta_r_hat      : 0.07 0.82 0.01 0.17 -0.07 -0.36 0 -0.63
sigsqr_beta_r_hat : 0.42
sigsqr_eps_hat  : 6.21
```

# Modellschätzung

Iteratives Verfahren zur Schätzung der Parameter eines Linear Mixed Models

$$\hat{y} = X_f \hat{\beta}_f + X_r \hat{\beta}_r$$



---

Modellformulierung

Generalisierte Kleinste-Quadrate Schätzung der Fixed-Effects

Varianzkomponentenschätzung mit Restricted Maximum-Likelihood

Bedingter Erwartungswert der Random-Effects

**Selbstkontrollfragen**

1. Geben Sie die Definition des Linear Mixed Models wieder.
2. Geben Sie das Theorem zur Marginalen Datenverteilung des Linear Mixed Models wieder.

- Bates, Douglas M, and Saikat DebRoy. 2004. "Linear Mixed Models and Penalized Least Squares." *Journal of Multivariate Analysis* 91 (1): 1–17. <https://doi.org/10.1016/j.jmva.2004.04.013>.
- Foulley, JL. 1993. "A Simple Argument Showing How to Derive Restricted Maximum Likelihood."
- Harville, David A. 1977. "Maximum Likelihood Approaches to Variance Component Estimation and to Related Problems." *Journal of the American Statistical Association* 72 (358): 320. <https://doi.org/10.2307/2286796>.
- Laird, Nan M. 1982. "Computation of Variance Components Using the Em Algorithm." *Journal of Statistical Computation and Simulation* 14 (3-4): 295–303. <https://doi.org/10.1080/00949658208810550>.
- Lindstrom, Mary J., and Douglas M. Bates. 1990. "Nonlinear Mixed Effects Models for Repeated Measures Data." *Biometrics* 46 (3): 673. <https://doi.org/10.2307/2532087>.
- Patterson, H. D., and R. Thompson. 1971. "Recovery of Inter-Block Information When Block Sizes Are Unequal." *Biometrika* 58 (3): 545–54. <https://doi.org/10.1093/biomet/58.3.545>.
- Searle, Shayle, George Casella, and Charles E. McCulloch. 1992. *Variance Components*. Wiley Series in Probability and Mathematical Statistics. New York: Wiley.
- Starke, Ludger, and Dirk Ostwald. 2017. "Variational Bayesian Parameter Estimation Techniques for the General Linear Model." *Frontiers in Neuroscience* 11 (September). <https://doi.org/10.3389/fnins.2017.00504>.
- Verbyla, A. P. 1990. "A Conditional Derivation of Residual Maximum Likelihood." *Australian Journal of Statistics* 32 (2): 227–30. <https://doi.org/10.1111/j.1467-842X.1990.tb01015.x>.