

Tutorium 3

Analyse longitudinaler Daten

Prof. Dr. Sonja Greven, Dipl. Stat. Jona Cederbaum,
Alexander Bauer

24. Mai 2016

- 1 Schätzung der Kovarianz von $\hat{\beta}$
- 2 Inferenz im LLMM

Schätzung der Kovarianz von $\hat{\beta}$

1 Schätzung der Kovarianz von $\hat{\beta}$

2 Inferenz im LLMM

Schätzung der Kovarianz von $\hat{\beta}$

Grundlagen:

- Schätzung basiert auf **marginalem Modell**:

$$\mathbf{Y}_i \sim \mathcal{N}(\mathbf{X}_i\boldsymbol{\beta}, \mathbf{V}_i(\boldsymbol{\alpha}))$$

mit $\mathbf{V}_i = \mathbf{Z}_i\mathbf{D}\mathbf{Z}_i^T + \boldsymbol{\Sigma}_i$

- Schätzung von $\hat{\beta}$ per GLS mit $\mathbf{W} = \mathbf{V}(\boldsymbol{\alpha})^{-1}$:

$$\hat{\beta}_{ML}(\boldsymbol{\alpha}) = \{\mathbf{X}^T\mathbf{W}\mathbf{X}\}^{-1}\mathbf{X}^T\mathbf{W}\mathbf{Y}$$

$$\text{Cov}(\hat{\beta}_{ML}) = \{\mathbf{X}^T\mathbf{W}\mathbf{X}\}^{-1}\{\mathbf{X}^T\mathbf{W} \text{Cov}(\mathbf{Y}) \mathbf{W}\mathbf{X}\}\{\mathbf{X}^T\mathbf{W}\mathbf{X}\}^{-1}$$

Schätzung der Kovarianz von $\hat{\beta}$

Schätzung von $Cov(\hat{\beta}_{ML})$:

- **Fall 1:** Kovarianz $Cov(\mathbf{Y})$ korrekt spezifiziert
⇒ Schätzer mit höchster Effizienz:

$$\widehat{Cov}(\hat{\beta}_{ML}) = \{\mathbf{X}^T \hat{\mathbf{V}}^{-1} \mathbf{X}\}^{-1}$$

- **Fall 2:** Kovarianz $Cov(\mathbf{Y})$ falsch spezifiziert
⇒ Obiger Schätzer liefert ungültige Standardfehler für β
(Inferenz folglich auch nicht mehr gültig)
⇒ Besser: Verwendung eines robusten Schätzers

Schätzung der Kovarianz von $\hat{\beta}$

Schätzung von $Cov(\hat{\beta}_{ML})$:

- Robuster Sandwich-Schätzer:

$$\widehat{Cov}(\hat{\beta}_{ML}) = \left\{ \sum_{i=1}^N \mathbf{x}_i^T \widehat{\mathbf{V}}_i^{-1} \mathbf{x}_i \right\}^{-1} \left\{ \sum_{i=1}^N \mathbf{x}_i^T \widehat{\mathbf{V}}_i^{-1} \widehat{Cov}(\mathbf{Y}_i) \widehat{\mathbf{V}}_i^{-1} \mathbf{x}_i \right\} \left\{ \sum_{i=1}^N \mathbf{x}_i^T \widehat{\mathbf{V}}_i^{-1} \mathbf{x}_i \right\}^{-1}$$

mit $\mathbf{V}_i = \mathbf{V}_i(\hat{\alpha})$ und $\widehat{Cov}(\mathbf{Y}_i) = \mathbf{r}_i \mathbf{r}_i^T = (\mathbf{y}_i - \mathbf{X}_i \hat{\beta})(\mathbf{y}_i - \mathbf{X}_i \hat{\beta})^T$

Vorteil: Auch bei Misspezifikation konsistent

Nachteile: Wenig effizient; Nicht zu empfehlen bei kleinem N

Inferenz im LLMM

- 1 Schätzung der Kovarianz von $\hat{\beta}$
- 2 Inferenz im LLMM

Inferenz im LLMM

Inferenz für fixed effects:

- Formulierung linearer Hypothesen $H_0 : \mathbf{L}\beta = \mathbf{0}$

Bsp.:

$$Y_{ij} = \beta_0 + \beta_1 x_{1ij} + \beta_2 x_{2ij} + b_i + \epsilon_{ij}$$

a) $H_0 : \beta_1 = 0 \quad \Leftrightarrow \quad \mathbf{L} = (0, 1, 0)$

b) $H_0 : \beta_1 = \beta_2 = 0 \quad \Leftrightarrow \quad \mathbf{L} = \begin{pmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$

c) $H_0 : \beta_1 = \beta_2 \quad \Leftrightarrow \quad \mathbf{L} = (0, 1, -1)$

\Rightarrow Testen per Wald-, t-, F- oder LQ-Test

Inferenz im LLMM

Inferenz für fixed effects:

$$T = (\hat{\beta} - \beta)^T \mathbf{L}^T \left[\mathbf{L} \widehat{\text{Cov}}(\hat{\beta}) \mathbf{L}^T \right]^{-1} \mathbf{L} (\hat{\beta} - \beta)$$

- Wald-Test:

$$(\hat{\beta} - \beta) \stackrel{a}{\sim} \mathcal{N}(\mathbf{0}, (\mathbf{X}^T \mathbf{V}(\hat{\alpha})^{-1} \mathbf{X})^{-1}), \quad T \stackrel{H_0, a}{\sim} \chi_{\text{rank}(\mathbf{L})}^2$$

Problem: Unsicherheit von $\hat{\alpha}$ wird in Schätzung \mathbf{V} nicht berücksichtigt

- t-Test & F-Test:

$$\text{t-Test (nur für skalare Hypothesen): } \frac{\hat{\beta}_k - \beta_k}{\widehat{SE}(\hat{\beta}_k)} \stackrel{H_0, a}{\sim} t_{\hat{df}}$$

$$\text{F-Test: } \frac{T}{\text{rank}(\mathbf{L})} \stackrel{H_0, a}{\sim} F_{\text{rank}(\mathbf{L}), \hat{df}}$$

\hat{df} wird aus Daten geschätzt

Anmerkung: Benutzung robuster Kovarianzen in allen Tests möglich

Inferenz im LLMM

Inferenz für fixed effects:

- LQ-Test für genestete Hypothesen:

$$\lambda_N = -2 \ln \left[\frac{L_{ML}(\hat{\theta}_{ML,0})}{L_{ML}(\hat{\theta}_{ML})} \right] \underset{H_0, a}{\sim} \chi_{p_{diff}}^2$$

LQ-Test bei kleinem N besser als Wald-Test

Voraussetzung: Gleiche random effects in den beiden Modellen

Beachten:

REML-Likelihoods abhängig von \mathbf{X} (durch Fehlerkontraste)

⇒ Likelihoods nicht vergleichbar bei unterschiedlichen fixed effects

⇒ LQ-Test zum Testen von fixed effects nur bei ML-Schätzung!

Inferenz im LLMM

Inferenz für Varianzparameter:

$$\text{Cov}(\mathbf{b}_i) = \mathbf{D} = \begin{pmatrix} d_{11} & d_{12} \\ d_{12} & d_{22} \end{pmatrix}$$

Vergleich dreier Modelle:

- M_0 : ohne random effects, $d_{11} = d_{12} = d_{22} = 0$
- M_1 : nur mit random intercept, $d_{12} = d_{22} = 0$
- M_2 : mit (korrelierten) random intercept und slope

Vergleich M_2 vs. M_1 durch $H_0 : d_{12} = d_{22} = 0$

Vergleich M_1 vs. M_0 durch $H_0 : d_{11} = 0$

Inferenz im LLMM

Inferenz für Varianzparameter:

- LQ-Test:

$$\lambda_N = -2 \ln \left[\frac{L_{ML/REML}(\hat{\theta}_{ML/REML,0})}{L_{ML/REML}(\hat{\theta}_{ML/REML})} \right]$$

Voraussetzung: Gleiche fixed effects in den beiden Modellen

Beachten:

Varianzparameter befinden sich unter H_0 am Rand des Parameterraums $[0, \infty)$

$\Rightarrow \lambda_N$ folgt unter H_0 einer Mischverteilung aus einer $\chi_{q_{diff}-1}^2$ - und einer $\chi_{q_{diff}}^2$ -Verteilung

Inferenz im LLMM

Parametrischer Bootstrap: als Alternative zu Mischverteilungsansatz

- 1) Fitte beide Modelle und berechne LQ-Teststatistik t_{obs} .
- 2) Für $b = 1, \dots, B$:
 - a) Simuliere neue y-Werte
 - b) Fitte beide Modelle erneut auf den neuen y-Werten und berechne die neue LQ-Teststatistik t^b . Die Werte t^b dienen als empirische Verteilung von t_{obs} unter H_0 .
- 3) Schätze den p-Wert:

$$p_{Boot} = \frac{\sum_{b=1}^B I_{t^b > t_{obs}} + 1}{B + 1}$$

Inferenz im LLMM

Parametrischer Bootstrap: als Alternative zu Mischverteilungsansatz

- 1) Fitte beide Modelle und berechne LQ-Teststatistik t_{obs} .
Notation: m_0 ist das Modell unter H_0 .
- 2) Für $b = 1, \dots, B$:
 - a) Simuliere neue y-Werte \Rightarrow 2 Möglichkeiten
 - i) Prognose mit $\hat{\beta}$ und $\hat{\mathbf{b}}_i$ aus m_0 , Simulation der ϵ_{ij} aus $\mathcal{N}(\mathbf{0}, \hat{\Sigma}_i)$
 - ii) Prognose mit $\hat{\beta}$ aus m_0 , Simulation sowohl der ϵ_{ij} aus $\mathcal{N}(\mathbf{0}, \hat{\Sigma}_i)$ als auch der $\hat{\mathbf{b}}_i$ aus $\mathcal{N}(\mathbf{0}, \mathbf{D})$
(In R: Selbst programmieren für `lme`, `simulate.merMod()` für `lmer`)
 - b) Fitte beide Modelle mit neuen y-Werten und berechne Teststatistik t^b
- 3) Schätze den p-Wert:

$$p_{Boot} = \frac{\sum_{b=1}^B I_{t^b > t_{obs}} + 1}{B + 1}$$

Inferenz im LLMM

Zusammenfassung:

- Korrekte Schätzung der Kovarianz von $\hat{\beta}$ zentral für Inferenz
- Testen linearer Hypothesen bzgl. der fixed effects - $\mathbf{L}\beta = \mathbf{0}$: (Wald-), t- oder F-Test
- Voraussetzungen LQ-Test:
 - Bei genesteten fixed effects: Gleiche random effects & ML
 - Bei genesteten random effects: Gleiche fixed effects
- In R: Verwendung von `anova.lme` (für `lme`-Modelle)