

Inhalt

- 1 Das lineare gemischte Modell
- 2 Likelihood-Schätzung für lineare gemischte Modelle
- 3 Likelihood-Inferenz im linearen gemischten Modell
- 4 Bayes-Schätzung für lineare gemischte Modelle
- 5 Additive gemischte Modelle
- 6 Das generalisierte lineare gemischte Modell
- 7 Likelihood-Schätzung für generalisierte lineare gemischte Modelle
 - Laplace-Approximation und P-IRLS
 - Adaptive Gauss-Hermite Quadratur (AGQ)
 - Penalized Quasi-Likelihood (PQL)
 - Inferenz in GLMMs

Likelihood eines GLMM

Verteilungsannahme für $\mathbf{y}|\mathbf{b}$: $y_i|\mathbf{b} \sim \text{Expo.fam.}(\boldsymbol{\theta}, \phi)$ unabhängig

Verteilungsannahme für $\mathbf{b}|\boldsymbol{\vartheta}$: $\mathbf{b}|\boldsymbol{\vartheta} \sim N(\mathbf{0}, \mathbf{G}(\boldsymbol{\vartheta}))$

⇒ gemeinsame / penalisierte Likelihood:

$$L(\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta}, \mathbf{b}) = f(\mathbf{y}, \mathbf{b}|\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta}) = \prod_{i=1}^n f(y_i|\boldsymbol{\beta}, \phi, \mathbf{b}, \boldsymbol{\vartheta})f(\mathbf{b}|\boldsymbol{\vartheta})$$

bzw. marginale Likelihood:

$$L(\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta}) = f(\mathbf{y}|\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta}) = \int \prod_{i=1}^n f(y_i|\boldsymbol{\beta}, \phi, \mathbf{b}, \boldsymbol{\vartheta})f(\mathbf{b}|\boldsymbol{\vartheta})d\mathbf{b}.$$

Erinnerung: im LMM ist das Integral analytisch lösbar.

$\int f(\mathbf{y}, \mathbf{b}|\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta})d\mathbf{b}$ ist die Dichte einer $N(\mathbf{X}\boldsymbol{\beta}, \mathbf{ZG}(\boldsymbol{\vartheta})\mathbf{Z}' + \mathbf{R}(\phi, \boldsymbol{\vartheta}))$ -Verteilung.

Im GLMM: ??

ML-Inferenz

Interessante Parameter: primär β, ϑ , evtl. ϕ

⇒ Problem: finde $\operatorname{argmax} L(\beta, \vartheta, \phi)$, wobei

$$\begin{aligned}
 L(\beta, \vartheta, \phi) &= \int \prod_{i=1}^n f(y_i | \beta, \phi, \mathbf{b}, \vartheta) f(\mathbf{b} | \vartheta) d\mathbf{b} \\
 &= \int \prod_{i=1}^n \exp\left(\frac{y_i \theta_i - b(\theta_i)}{\phi} - c(y_i, \phi)\right) |\mathbf{G}(\vartheta)|^{-1/2} \exp\left(-\frac{1}{2} \mathbf{b}' \mathbf{G}(\vartheta)^{-1} \mathbf{b}\right) d\mathbf{b} \\
 &\quad \text{mit } \theta_i = (b')^{-1}(g^{-1}(\eta_i)), \quad \eta_i = \mathbf{x}'_i \beta + \mathbf{z}'_i \mathbf{b}.
 \end{aligned}$$

Hoch-dimensionales Integral, i.A. nicht analytisch lösbar

⇒ iterative Optimierung einer Approximation der Likelihood

Laplace-Approximation

Problem: Löse q -dimensionales Integral $H = \int \exp(h(\boldsymbol{\theta})) d\boldsymbol{\theta}$

Ansatz:

- bestimme $\boldsymbol{\theta}_0 = \arg \max h(\boldsymbol{\theta})$

- quadratische Taylor-Entwicklung von $h(\boldsymbol{\theta})$ um $\boldsymbol{\theta}_0$:

$$h(\boldsymbol{\theta}) \approx h(\boldsymbol{\theta}_0) + \frac{1}{2}(\boldsymbol{\theta} - \boldsymbol{\theta}_0)' \underbrace{\left(\frac{\partial^2}{\partial \boldsymbol{\theta} \boldsymbol{\theta}'} h(\boldsymbol{\theta}_0) \right)}_{=-\mathbf{P}} (\boldsymbol{\theta} - \boldsymbol{\theta}_0)$$

- $\Rightarrow \int \exp(h(\boldsymbol{\theta})) d\boldsymbol{\theta} \approx \int \exp(h(\boldsymbol{\theta}_0) - \frac{1}{2}(\boldsymbol{\theta} - \boldsymbol{\theta}_0)' \mathbf{P} (\boldsymbol{\theta} - \boldsymbol{\theta}_0)) d\boldsymbol{\theta}$
wie bei $N(\boldsymbol{\theta}_0, \mathbf{P}^{-1})$

- $\Rightarrow H \approx \exp(h(\boldsymbol{\theta}_0)) \underbrace{((2\pi)^{q/2} |\mathbf{P}|^{-1/2})}_{1/\text{Normierung der } N(\boldsymbol{\theta}_0, \mathbf{P}^{-1})}$

GLMM-Likelihood: Laplace-Approximation

Verwende eine Laplace-Approximation, mit Entwicklung um den Maximierer $\hat{\mathbf{b}}$ von $L(\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta}, \mathbf{b}) = f(\mathbf{y}|\boldsymbol{\beta}, \phi, \mathbf{b})f(\mathbf{b}|\boldsymbol{\vartheta})$, für

$$\begin{aligned} \log(L(\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta})) &= \log \left(\int f(\mathbf{y}|\boldsymbol{\beta}, \phi, \mathbf{b})f(\mathbf{b}|\boldsymbol{\vartheta})d\mathbf{b} \right) \\ &= \log \left(\int L(\boldsymbol{\beta}, \phi, \mathbf{b})(2\pi)^{-q/2}|\mathbf{G}(\boldsymbol{\vartheta})|^{-\frac{1}{2}} \exp \left(-\frac{1}{2}\mathbf{b}'\mathbf{G}(\boldsymbol{\vartheta})^{-1}\mathbf{b} \right) d\mathbf{b} \right) \\ &\approx \log(L(\boldsymbol{\beta}, \hat{\mathbf{b}}, \phi)) - \frac{q}{2} \log(2\pi) - \frac{1}{2} \log |\mathbf{G}(\boldsymbol{\vartheta})| - \frac{1}{2} \hat{\mathbf{b}}' \mathbf{G}(\boldsymbol{\vartheta})^{-1} \hat{\mathbf{b}} \\ &\quad + \log \left(\int \exp \left(-\frac{1}{2}(\mathbf{b} - \hat{\mathbf{b}})' \mathcal{I}(\hat{\mathbf{b}})(\mathbf{b} - \hat{\mathbf{b}}) \right) d\mathbf{b} \right) \\ &= l(\boldsymbol{\beta}, \hat{\mathbf{b}}, \phi) - \frac{1}{2} \log |\mathcal{I}(\hat{\mathbf{b}})| - \frac{1}{2} \log |\mathbf{G}(\boldsymbol{\vartheta})| - \frac{1}{2} \hat{\mathbf{b}}' \mathbf{G}(\boldsymbol{\vartheta})^{-1} \hat{\mathbf{b}}. \end{aligned}$$

Dabei ist $\mathcal{I}(\mathbf{b}) = -E \left(\frac{\partial^2}{\partial \mathbf{b} \partial \mathbf{b}'} l(\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta}, \mathbf{b}) \right)$ (mit zusätzlichem Erwartungswert), Herleitung siehe S. 156.

Schaukel-Algorithmus

In der Laplace-Approximation wird der Maximierer $\hat{\mathbf{b}}$ von $L(\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta}, \mathbf{b})$ benötigt.
⇒ iterativer, zweistufiger Schaukel-Algorithmus:

- 1 Für gegebene $\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta}$ bestimme $\hat{\mathbf{b}} = \arg \max_{\mathbf{b}} L(\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta}, \mathbf{b})$ über penalisierten IRLS-Algorithmus (P-IRLS).
- 2 Maximiere Laplace-Approximation $\tilde{L}(\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta})$ von $L(\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta})$ in $\hat{\mathbf{b}}$ mit numerischer Optimierung (Pseudo-Newton-Algorithmen wie BFGS).

Iteriere bis zur Konvergenz der Devianz $-2 \log L(\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta}, \mathbf{b})$.

Dieser Schaukel-Algorithmus ist im R-Paket [lme4](#) implementiert.

Grundidee: IRLS-Algorithmus

- IRLS = Fisher-Scoring für GLM
 - IRLS: Iteratively Re-Weighted Least Squares
 - Führt GLM-Schätzproblem auf iterierte gewichtete KQ-Schätzung zurück.
- Fisher-Scoring zur Lösung des Score-Gleichungssystems $s(\boldsymbol{\theta}) \stackrel{!}{=} 0$
 - lineare Taylor-Entwicklung $s(\boldsymbol{\theta}) \approx s(\boldsymbol{\theta}_0) - \mathcal{J}(\boldsymbol{\theta}_0)(\boldsymbol{\theta} - \boldsymbol{\theta}_0) \stackrel{!}{=} 0$ mit der beobachteten Informationsmatrix $\mathcal{J}(\boldsymbol{\theta})$.
 - Ersetzen von $\mathcal{J}(\boldsymbol{\theta})$ (Newton-Raphson) durch die erwartete Informationsmatrix $\mathcal{I}(\boldsymbol{\theta})$ (Fisher-Scoring) liefert

$$\mathcal{I}(\boldsymbol{\theta}_0)\boldsymbol{\theta} = \mathcal{I}(\boldsymbol{\theta}_0)\boldsymbol{\theta}_0 + s(\boldsymbol{\theta}_0).$$

$s(\mathbf{b})$ und $\mathcal{I}(\mathbf{b})$ für den kanonischen Link

Für den kanonischen Link ist $\boldsymbol{\theta} = \mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\mathbf{b}$.

$$\begin{aligned}\Rightarrow s(\mathbf{b}) &= \frac{\partial}{\partial \mathbf{b}} l(\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta}, \mathbf{b}) = \frac{\partial}{\partial \mathbf{b}} \left(\text{const} + \frac{\boldsymbol{\theta}'\mathbf{y} - b(\boldsymbol{\theta})'\mathbf{1}}{\phi} - \frac{1}{2}\mathbf{b}'\mathbf{G}(\boldsymbol{\vartheta})^{-1}\mathbf{b} \right) \\ &= \frac{1}{\phi} (\mathbf{Z}'\mathbf{y} - \mathbf{Z}' \text{diag}(b'(\boldsymbol{\theta}))\mathbf{1}) - \mathbf{G}(\boldsymbol{\vartheta})^{-1}\mathbf{b} \\ &= \frac{1}{\phi} \mathbf{Z}'(\mathbf{y} - \boldsymbol{\mu}) - \mathbf{G}(\boldsymbol{\vartheta})^{-1}\mathbf{b} \quad \text{und}\end{aligned}$$

$$\begin{aligned}\mathcal{I}(\mathbf{b}) &= -\text{E} \left(\frac{\partial^2}{\partial \mathbf{b} \partial \mathbf{b}'} l(\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta}, \mathbf{b}) \right) = - \left(\frac{\partial}{\partial \mathbf{b}'} s(\mathbf{b}) \right) \\ &= \frac{1}{\phi} \mathbf{Z} \text{diag}(b''(\boldsymbol{\theta})) \mathbf{Z}' + \mathbf{G}(\boldsymbol{\vartheta})^{-1} =: \mathbf{Z}\mathbf{W}\mathbf{Z}' + \mathbf{G}(\boldsymbol{\vartheta})^{-1}\end{aligned}$$

P-IRLS

Fisher-Scoring ausgehend von Startwert \mathbf{b}_0 :

$$\mathcal{I}(\mathbf{b}_0)\mathbf{b} = \mathcal{I}(\mathbf{b}_0)\mathbf{b}_0 + s(\mathbf{b}_0)$$

mit im GLMM:
$$s(\mathbf{b}) = \frac{1}{\phi} \mathbf{Z}'(\mathbf{y} - \boldsymbol{\mu}) - \mathbf{G}(\boldsymbol{\vartheta})^{-1}\mathbf{b};$$

$$\mathcal{I}(\mathbf{b}) = \mathbf{Z}'\mathbf{W}\mathbf{Z} + \mathbf{G}(\boldsymbol{\vartheta})^{-1}$$

liefert mit $\mathbf{W}_0 = \mathbf{W}(\mathbf{b}_0)$, $\boldsymbol{\mu}_0 = \boldsymbol{\mu}(\mathbf{b}_0)$:

$$(\mathbf{Z}'\mathbf{W}_0\mathbf{Z} + \mathbf{G}(\boldsymbol{\vartheta})^{-1})\mathbf{b} = (\mathbf{Z}'\mathbf{W}_0\mathbf{Z} + \mathbf{G}(\boldsymbol{\vartheta})^{-1})\mathbf{b}_0 + \frac{1}{\phi} \mathbf{Z}'(\mathbf{y} - \boldsymbol{\mu}_0) - \mathbf{G}(\boldsymbol{\vartheta})^{-1}\mathbf{b}_0$$

$$(\mathbf{Z}'\mathbf{W}_0\mathbf{Z} + \mathbf{G}(\boldsymbol{\vartheta})^{-1})\mathbf{b} = \underbrace{\mathbf{Z}'\mathbf{W}_0(\mathbf{Z}\mathbf{b}_0 + \frac{1}{\phi} \mathbf{W}_0^{-1}(\mathbf{y} - \boldsymbol{\mu}_0))}_{\text{working response } \tilde{\mathbf{y}}}$$

⇒ Schätzgleichung eines LMM mit bekanntem \mathbf{W}_0 , $\mathbf{G}(\boldsymbol{\vartheta})$, vgl. (14):

$$\tilde{\mathbf{y}}|\mathbf{b} \sim N(\mathbf{Z}\mathbf{b}, \mathbf{W}_0^{-1}); \mathbf{b} \sim N(\mathbf{0}, \mathbf{G}(\boldsymbol{\vartheta}))$$

P-IRLS

P-IRLS-Algorithmus iteriert folgende Schritte bis zur Konvergenz von \mathbf{b} :

- i. setze Iterationswert $\mathbf{b}_0 = \hat{\mathbf{b}}^{(k)}$, berechne mit β , \mathbf{b}_0 die working responses $\tilde{\mathbf{y}}$ und Gewichte \mathbf{W}_0
- ii. berechne $\hat{\mathbf{b}}^{(k+1)}$ als Lösung des daraus abgeleiteten gewichteten, penalierten KQ-Problems

(Adaptive) Gauss'sche Quadratur

- Laplace-Approximation recht schnell, aber ungenau besonders für kleine Clustergrößen und starke „Diskretheit“ (logistische Regression schlechter als Poisson-Regression)
- Gauss-Quadratur genauere Methode, um $\int f(\mathbf{y}|\boldsymbol{\beta}, \phi, \mathbf{b})f(\mathbf{b}|\boldsymbol{\vartheta})d\mathbf{b}$ zu approximieren, aber wesentlich rechenaufwändiger
- Benutzt orthonormalisierte zufällige Effekte $\mathbf{b}^* = \mathbf{G}(\boldsymbol{\vartheta})^{-1/2}\mathbf{b}$
- $\int f(\mathbf{y}|\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta}, \mathbf{b}^*)f(\mathbf{b}^*)d\mathbf{b}^* \approx \sum_{q=1}^Q w_q f(\mathbf{y}|\boldsymbol{\beta}, \phi, \boldsymbol{\vartheta}, \mathbf{b}_q^*)$
- Die Stützstellen \mathbf{b}_q^* ergeben sich aus den Nullstellen des Q-ten Hermite-Polynoms und bestimmen auch die Gewichte w_q

(Adaptive) Gauss'sche Quadratur

- Genauigkeit der Approximation steigt mit wachsendem Q
⇒ erhöhe Q solange bis keine Änderung in Schätzung mehr zu beobachten
- in `lme4` nur implementiert für Modelle mit *einer* einzigen Gruppierungsvariable (option: `nAGQ`)
- Laplace-Approximation ergibt sich als Spezialfall $Q = 1$.

Penalized Quasi-Likelihood (PQL):

Ähnliche Idee wie P-IRLS: Approximiere \mathbf{y} durch $\boldsymbol{\mu} = E(\mathbf{y}|\mathbf{b})$ plus Fehler mit Varianz $\text{Var}(\mathbf{y}|\mathbf{b})$. Eine Taylor-Approximation von $\boldsymbol{\mu}$ und Umsortieren ergibt

$$\tilde{\mathbf{y}} := \mathbf{X}\boldsymbol{\beta}_0 + \mathbf{Z}\mathbf{b}_0 + \frac{1}{\phi} \mathbf{W}_0^{-1}(\mathbf{y} - \boldsymbol{\mu}_0) = \mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\mathbf{b} + \boldsymbol{\varepsilon}.$$

Algorithmus:

- 1 Für gegebene Werte $\boldsymbol{\beta}_0 = \hat{\boldsymbol{\beta}}^{(k)}$, $\mathbf{b}_0 = \hat{\mathbf{b}}^{(k)}$ bestimme *working responses* $\tilde{\mathbf{y}}$.
- 2 Bestimme $\hat{\boldsymbol{\beta}}^{(k+1)}$, $\hat{\mathbf{b}}^{(k+1)}$ und $\hat{\boldsymbol{\vartheta}}^{(k+1)}$, $\hat{\phi}^{(k+1)}$ aus dem LMM $\tilde{\mathbf{y}} = \mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\mathbf{b} + \boldsymbol{\varepsilon}$ mit $\mathbf{b} \sim N(\mathbf{0}, \mathbf{G}(\boldsymbol{\vartheta}))$ und $\boldsymbol{\varepsilon} \sim N(\mathbf{0}, \mathbf{W}_0^{-1})$

Iteriere bis zur Konvergenz des erweiterten linearen Prädiktors.

PQL

- Alternative Herleitung für PQL: ergibt sich ebenfalls bei Fisher-Scoring für die gemeinsame/penalisierte log-Likelihood (die im LMM die BLUPs ergibt). Daher auch mögliche Schätzart bei GAMMs.
- in R implementiert in Funktion `glmmPQL` im Paket MASS (`glmmPQL` wird auch von Funktion `gamm` im Paket `mgcv` benutzt)
- benutzt iterierte ML- oder REML-Schätzung
- Schätzung der Varianzparameter nach unten verzerrt, v.a. falls n_i klein. Bessere Approximation, je näher Daten an Normalverteilung (z.B. Poisson-Verteilung mit größeren λ 's)
- Konvergenz nicht garantiert
- Kein AIC, BIC oder Devianz berechenbar

Vergleich glmmPQL/lme vs. lmer

	MASS::glmmPQL	lme4::lmer
Daten	nur genestete Daten; grosse Datensätze/Modelle oft nicht zu fitten	genestete & gekreuzte Datenstrukturen; auch riesige Datensätze werden gefittet
(G)AMs	via mgcv::gamm	via gamm4
Cov(\mathbf{b}_i)	sehr breite, erweiterbare Klasse von Kovarianzstrukturen (s. nlme::pdMat)	nur unstrukturierte oder diagonale Kovarianzen (in gamm4 beliebige Präzisionsmatrizen \mathbf{P} mit $\mathbf{G}(\vartheta) = \vartheta \mathbf{P}^{-1}$)
Cov(ε)	sehr breite, erweiterbare Klasse von Kovarianzstrukturen (s. nlme::varFunc)	Cov(ε) = $\sigma^2 \mathbf{I}_n$
Stabilität	sehr instabil für komplexe Strukturen von \mathbf{b}	sehr stabil für LMMs; für GLMMs ab > 3 zuf. Effekten oft kritisch
Speed	relativ langsam	LA sehr schnell (benutzt Sparse-Matrix-Algorithmen); AGQ deutlich langsamer

(Stand: Oktober 2013)

Vorhersage der zufälligen Effekte

Die beste Vorhersage für \mathbf{b} (minimaler mean squared error of prediction $E(\mathbf{b} - \hat{\mathbf{b}})^2$) wäre wieder

$$\hat{\mathbf{b}} = E(\mathbf{b}|\mathbf{y}).$$

In der Praxis würde man $\hat{\beta}$ und $\hat{\vartheta}$ einsetzen. Allerdings erfordert

$$\hat{\mathbf{b}} = \int \mathbf{b}f(\mathbf{b}|\mathbf{y}, \beta, \vartheta) d\mathbf{b} = \frac{\int \mathbf{b}f(\mathbf{y}|\mathbf{b}, \beta, \phi)f(\mathbf{b}|\vartheta) d\mathbf{b}}{\int f(\mathbf{y}|\mathbf{b}, \beta, \phi)f(\mathbf{b}|\vartheta) d\mathbf{b}}$$

wieder numerische Integration.

Alternativ zum Posteriori-EW wird häufig (z.B. in lme4 als Teil von P-IRLS) der Posteriori-Modus berechnet, der $f(\mathbf{b}|\mathbf{y}, \beta, \vartheta) \propto f(\mathbf{y}|\mathbf{b}, \beta, \phi)f(\mathbf{b}|\vartheta_0)$ maximiert. Die beiden unterscheiden sich i.A. außer im LMM unter NV.

PQL schätzt \mathbf{b} direkt im Schätzalgorithmus.

Hypothesen-Tests für β

- Wegen der Maximum-Likelihood-Schätzung von β können prinzipiell Wald-, Likelihood-Quotienten- (LQT) oder Score-Tests verwendet werden mit einer entsprechenden χ^2 -Verteilung als Referenzverteilung.
- Die Güte der Approximation hängt ab von
 - der Güte der Approximation an die Likelihood in der Schätzung
 - der Güte der asymptotischen Approximation, die nur für Longitudinal/Clusterdaten bei $m \rightarrow \infty$ greift.
- PQL-Schätzung beruht auf der Likelihood von Pseudodaten und daher ist kein Likelihood-Quotiententest möglich. Inferenz für PQL wird meist basiert auf dem LMM in der PQL-Schätzung. Allerdings ist $\hat{\beta}$ i.A. nicht konsistent.

Hypothesen-Tests für D

- Für das longitudinale/Cluster-GLMM gelten die gleichen asymptotischen Ergebnisse für Tests von Parametern in D wie im LMM (Rand des Parameterraums).
- Es ist keine exakte Verteilung vorhanden.

Konfidenzintervalle

- Generell gilt für einen Parameter θ :
Ein Wert θ_0 ist im $(1 - \alpha)\%$ -Konfidenzintervall für $\theta \Leftrightarrow$ Die Hypothese $H_0 : \theta = \theta_0$ gegen $H_A : \theta \neq \theta_0$ wird zum Level α nicht verworfen.
(Sofern Test und Konfidenzintervall auf der gleichen Statistik beruhen.)
- Im GLMM: Für Parameter θ in β , ϕ oder \mathbf{D} , betrachte ein Gitter von θ_0 -Werten um den Schätzer $\hat{\theta}$.
- Konstruiere das Konfidenzintervall für θ so, dass alle Werte auf dem Gitter enthalten sind, für die ein LQT mit Referenzverteilung χ_1^2 H_0 nicht ablehnt.
- Dieser Ansatz funktioniert auch bei nicht-symmetrischen Verteilungen von Schätzern, jedoch nicht bei Parametern θ_0 in \mathbf{D} nahe des Randes des Parameterraums.
- Der Ansatz ist in `lme4` implementiert in der Funktion `confint`.