

# 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
  - Wiederholung: Bayes-Inferenz
  - Bayesianisches LMM
  - Empirische Bayes-Schätzung
  - Volle Bayes-Schätzung
  - Erweiterungen: Flexiblere Verteilung der zufälligen Effekte

# Wiederholung: Bayes-Inferenz

- Parameter  $\theta \in \Theta$  nicht deterministisch, sondern als zufällig angenommen.
- Volles Wahrscheinlichkeitsmodell für alle beobachteten und unbeobachteten Größen bestehend aus:
  - 1 **Beobachtungsmodell:** bedingte Verteilung der Daten gegeben unbekannte Parameter  $\theta$ ,  $p(y|\theta)$ .
  - 2 **Priori-Verteilung**  $p(\theta)$ : drückt Vorwissen/Annahmen über  $\theta$  aus.
- Mathematisch günstig: zum Beobachtungsmodell **konjugierte Prioris**. (Prioris und Posterioris in der gleichen Verteilungsfamilie.)
- Informationsgehalt der Priori: **nicht** oder **schwach informative Prioris**.

# Wiederholung: Bayes-Inferenz

- **Statistische Schlüsse** basieren auf der **Posteriori-Verteilung**  $p(\boldsymbol{\theta}|\mathbf{y})$ ,  $\boldsymbol{\theta} \in \Theta$ , der bedingten Verteilung der unbeobachteten Größen gegeben die beobachteten Daten.
- **Berechnung** mit dem Satz von Bayes:

$$p(\boldsymbol{\theta}|\mathbf{y}) = \frac{p(\mathbf{y}|\boldsymbol{\theta}) p(\boldsymbol{\theta})}{\int_{\Theta} p(\mathbf{y}|\boldsymbol{\theta}) p(\boldsymbol{\theta}) d\boldsymbol{\theta}} \propto p(\mathbf{y}|\boldsymbol{\theta}) p(\boldsymbol{\theta})$$

mit der **Normierungskonstanten** der Posteriori-Dichte im Nenner.

# Wiederholung: Bayes-Inferenz

- Übliche **Punktschätzer** der Bayesianischen Inferenz:
  - Posteriori-Erwartungswert  $\hat{\theta} = E(\theta|\mathbf{y})$ ,
  - Posteriori-Median  $\hat{\theta} = \inf \{\theta : F(\theta|\mathbf{y}) \geq 0.5\}$ ,
  - Posteriori-Modus  $\hat{\theta} = \arg \max \{p(\theta|\mathbf{y})\}$ .
- **Problem:** Posteriori-Verteilung meist analytisch unzugänglich
- **Lösung:** Verwendung von **MCMC-Verfahren**, mit denen (abhängige) Zufallszahlen aus der Posteriori Verteilung gezogen werden können.

# Grundidee MCMC

- Konstruiere Markov-Kette (MK), deren stationäre Verteilung mit der Posteriori Verteilung übereinstimmt.
- Zustände der MK entsprechen gezogenen Zufallszahlen, die (nach entsprechender Konvergenzzeit (Burn-In-Phase) der MK) abhängige Stichprobe aus Posteriori darstellen.
- Abhängigkeit kann durch geeignetes Ausdünnen der Stichprobe reduziert werden.
- Interessierende Größen (z.B. P.-Erwartungswert), werden dann aus dieser (ausgedünnten) Stichprobe durch die **empirischen Analog**a geschätzt.
- Bekanntester Algorithmus: **Metropolis-Hastings-Algorithmus**, Spezialfall: **Gibbs-Sampler**

# Beobachtungsmodell

Beobachtungsmodell:

$$\mathbf{y} | \boldsymbol{\beta}, \mathbf{b}, \boldsymbol{\vartheta} \sim N(\mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\mathbf{b}, \mathbf{R}(\boldsymbol{\vartheta}))$$

entspricht  $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\mathbf{b} + \boldsymbol{\varepsilon}$  mit  $\boldsymbol{\varepsilon} \sim N(\mathbf{0}, \mathbf{R}(\boldsymbol{\vartheta}))$ .

## Priori für $\beta$

- Jetzt auch „feste“ Effekte  $\beta$  als **Zufallsgrößen**
- kein Vorwissen über  $\beta \Rightarrow$  **nichtinformative Priori**, d.h.

$$p(\beta) \propto \text{const},$$

sonst

$\beta \sim N(\mathbf{m}, \mathbf{M})$  mit bekanntem EWert  $\mathbf{m}$ , Kovarianz  $\mathbf{M}$ .

- nichtinformative Priori  $p(\beta) \propto \text{const}$  ergibt sich als Grenzfall der Priori-Normalverteilung (NV) für **Präzisionsmatrix**  $\mathbf{M}^{-1} \rightarrow \mathbf{0}$ .
- zum Beobachtungsmodell **konjugierte Normalverteilung** für  $\beta$   
 $\Rightarrow$  Posteriori-Inferenz vergleichsweise einfach.

## Prioris für $\mathbf{b}$ , $\varepsilon$

Üblicherweise:

$$\mathbf{b} \sim N(\mathbf{0}, \mathbf{G}(\vartheta)); \quad \varepsilon \sim N(\mathbf{0}, \mathbf{R}(\vartheta))$$

- Kovarianzmatrizen  $\mathbf{G} = \text{Cov}(\mathbf{b})$  und  $\mathbf{R} = \text{Cov}(\varepsilon)$  hängen i.A. von unbekanntem **Hyperparametern** im Vektor  $\vartheta$  ab.
- **Voller Bayes-Ansatz:**  
 $\vartheta$  ebenfalls **Zufallsvariable**, mit (Hyper-)Priori  $p(\vartheta)$ , die in Ermittlung der Posteriori mit einfließt.
- **empirischer Bayes-Ansatz:**  
 $\vartheta$  als unbekannter, aber **fester Parameter**.

**Weitere Annahme:** Zufallsgrößen  $\beta$ ,  $\mathbf{b}$  und  $\varepsilon$  a priori **unabhängig**.



# Gemeinsame Posteriori bei NV-Priori für $\beta$ und $b$

$$\begin{aligned}
 p(\beta, \mathbf{b} | \mathbf{y}) &\propto p(\mathbf{y} | \beta, \mathbf{b}) p(\beta) p(\mathbf{b}) \\
 &\propto \exp \left( -\frac{1}{2} (\mathbf{y} - \mathbf{X}\beta - \mathbf{Z}\mathbf{b})' \mathbf{R}^{-1} (\mathbf{y} - \mathbf{X}\beta - \mathbf{Z}\mathbf{b}) \right. \\
 &\quad \left. - \frac{1}{2} (\beta - \mathbf{m})' \mathbf{M}^{-1} (\beta - \mathbf{m}) - \frac{1}{2} \mathbf{b}' \mathbf{G}^{-1} \mathbf{b} \right).
 \end{aligned}$$

$$\Rightarrow \begin{pmatrix} \beta \\ \mathbf{b} \end{pmatrix} \Big| \mathbf{y} \sim N(\boldsymbol{\mu}_{\beta, \mathbf{b}}, \boldsymbol{\Sigma}_{\beta, \mathbf{b}}) \text{ (Übung) mit}$$

$$\boldsymbol{\Sigma}_{\beta, \mathbf{b}} = (\mathbf{C}' \mathbf{R}^{-1} \mathbf{C} + \mathbf{A})^{-1}; \quad \mathbf{C} = [\mathbf{X} | \mathbf{Z}]; \quad \mathbf{A} = \begin{bmatrix} \mathbf{M}^{-1} & \mathbf{0} \\ \mathbf{0} & \mathbf{G}^{-1} \end{bmatrix}$$

$$\boldsymbol{\mu}_{\beta, \mathbf{b}} = \boldsymbol{\Sigma}_{\beta, \mathbf{b}} (\tilde{\mathbf{m}} + \mathbf{C}' \mathbf{R}^{-1} \mathbf{y}); \quad \tilde{\mathbf{m}} = \begin{pmatrix} \mathbf{M}^{-1} \mathbf{m} \\ \mathbf{0} \end{pmatrix}$$

## Posteriori bei nichtinformativer Priori für $\beta$

Nichtinformative Priori  $p(\beta) \propto \text{const}$  entspricht Präzisionsmatrix  $\mathbf{M}^{-1} = \mathbf{0}$ :

$$p(\beta, \mathbf{b} | \mathbf{y}) \propto p(\mathbf{y} | \beta, \mathbf{b}) p(\mathbf{b}) \\ \propto \exp \left( -\frac{1}{2} (\mathbf{y} - \mathbf{X}\beta - \mathbf{Z}\mathbf{b})' \mathbf{R}^{-1} (\mathbf{y} - \mathbf{X}\beta - \mathbf{Z}\mathbf{b}) - \frac{1}{2} \mathbf{b}' \mathbf{G}^{-1} \mathbf{b} \right)$$

$$\Rightarrow \text{Posteriori-EW für } \begin{pmatrix} \beta \\ \mathbf{b} \end{pmatrix}: (\mathbf{C}' \mathbf{R}^{-1} \mathbf{C} + \mathbf{A})^{-1} \mathbf{C}' \mathbf{R}^{-1} \mathbf{y}$$

$$\Rightarrow \text{Posteriori-Kov. für } \begin{pmatrix} \beta \\ \mathbf{b} \end{pmatrix}: (\mathbf{C}' \mathbf{R}^{-1} \mathbf{C} + \mathbf{A})^{-1}$$

- **Posteriori** äquivalent zu **penalisiertem KQ-Kriterium**  $KQ_{pen}(\beta, \mathbf{b})$  in (16)
- **Posteriori-Modus** als Maximierer identisch mit **BLUP-Schätzern**, die  $KQ_{pen}(\beta, \mathbf{b})$  minimieren. **Posteriori-EW** = Posteriori-Modus wegen NV.
- Posteriori-Kov. identisch mit Kovarianz in (21).

# Empirische Bayes-Schätzung

- **Empirische Bayes-Schätzer** für  $\beta$ ,  $\mathbf{b}$  durch Einsetzen der geschätzten Kovarianzmatrizen  $\hat{\mathbf{G}} = \mathbf{G}(\hat{\vartheta})$  und  $\hat{\mathbf{R}} = \mathbf{R}(\hat{\vartheta})$  in vorige Ausdrücke.

- Schätzung von  $\hat{\vartheta}$  durch Maximieren der **marginalen Likelihood** für  $\vartheta$ :

$$\hat{\vartheta} = \arg \max p(\mathbf{y}|\vartheta) = \arg \max \int p(\mathbf{y}|\beta, \mathbf{b}, \vartheta)p(\mathbf{b}|\vartheta)p(\beta)d\beta d\mathbf{b}.$$

- Für nicht-informative  $p(\beta) \propto \text{const}$  ist die **marginale Likelihood**

$$p(\mathbf{y}|\vartheta) = \int p(\mathbf{y}|\beta, \mathbf{b}, \vartheta)p(\mathbf{b}|\vartheta)d\beta d\mathbf{b} = \int p(\mathbf{y}|\beta, \vartheta)d\beta$$

proportional zur **restringierten Likelihood**  $\exp\{l_R(\vartheta)\}$ , siehe (20).

$\Rightarrow$  emp. Bayes-Schätzer in diesem Fall äquivalent zu **REML-Schätzer**  $\hat{\vartheta}_{REML}$  und den dazugehörigen EBLUPs für  $\beta$  und  $\mathbf{b}$ .

# Volle Bayes-Inferenz

- **Voller Bayes-Ansatz:** Priori-Verteilung  $p(\vartheta)$  auch für unbekannte Parameter  $\vartheta$ ;  $\beta$ ,  $\mathbf{b}|\vartheta$  und  $\vartheta$  als unabhängig angenommen.
- Inferenz basiert auf **Posteriori-Verteilung**

$$p(\beta, \mathbf{b}, \vartheta | \mathbf{y}) \propto p(\mathbf{y} | \beta, \mathbf{b}, \vartheta) p(\beta) p(\mathbf{b} | \vartheta) p(\vartheta)$$

- $p(\beta, \mathbf{b}, \vartheta | \mathbf{y})$  echte Posteriori-Dichte, wenn zur **Normierung** gilt:

$$p(\mathbf{y}) = \int p(\mathbf{y} | \beta, \mathbf{b}, \vartheta) p(\beta) p(\mathbf{b} | \vartheta) p(\vartheta) d\beta d\mathbf{b} d\vartheta < \infty.$$

- Bei echter, **informativer** Priori mit  $\int p(\vartheta) d\vartheta = 1$  existiert auch  $p(\beta, \mathbf{b}, \vartheta | \mathbf{y})$ .
- Für **nichtinformativ** Priori mit  $\int p(\vartheta) d\vartheta = \infty$  Existenz der Posteriori nicht allgemein gesichert.

## Beziehungen zur Likelihood-Inferenz

Bei nichtinformativer Priori  $p(\vartheta) \propto \text{const}$  und Existenz der Posteriori:

- **REML-Schätzer**  $\hat{\vartheta}_{REML}$  als Maximierer der marginalen Likelihood = Posteriori-Modus der marginalen Posteriori von  $\vartheta$  wegen

$$p(\vartheta|\mathbf{y}) = p(\mathbf{y}|\vartheta) \frac{p(\vartheta)}{p(\mathbf{y})} \propto p(\mathbf{y}|\vartheta).$$

- Bei zusätzlich nichtinformativer Priori  $p(\beta) \propto \text{const}$ : **ML-Schätzer**  $\hat{\vartheta}_{ML}$  als Maximierer der Likelihood =  $\vartheta$ -Komponente des Posteriori-Modus der gemeinsamen Posteriori von  $\beta$  und  $\vartheta$  wegen

$$p(\beta, \vartheta|\mathbf{y}) = p(\mathbf{y}|\vartheta, \beta) \frac{p(\vartheta)p(\beta)}{p(\mathbf{y})} \propto p(\mathbf{y}|\vartheta, \beta).$$

# Inferenz

- Normierungskonstante der Posteriori i.A. nicht analytisch zugänglich  
⇒ Posteriori-Dichte  $p(\beta, \mathbf{b}, \vartheta | \mathbf{y})$  **nicht in geschlossener Form** darstellbar
- volle Bayes-Inferenz daher üblicherweise mittels **MCMC-Simulation**  
(Details siehe z.B. Fahrmeir et al. (2007, Abschnitt B.5.3))
- moderne (approximative) Alternativen:  
**INLA** (Integrated Nested Laplace Approximation),  
**Variational Bayes**-Verfahren

# MCMC mit blockweisem Gibbs-Sampling

Vorgehen: Teile Parametervektor  $\theta = (\beta, \mathbf{b}, \vartheta)$  in **Teilvektoren** **zusammengehöriger Parameter**, d.h. üblicherweise  $\beta$ ,  $\mathbf{b}$  und  $\vartheta$  auf.

- Wähle Startwerte  $\beta^{(0)}$ ,  $\mathbf{b}^{(0)}$ ,  $\vartheta^{(0)}$  und Anzahl der Iterationen  $T$
- Bilde **vollständig bedingte Dichten** (full conditionals) gegeben der restlichen Parameter und  $\mathbf{y}$
- Ziehe **sequentiell Zufallszahlen**  $\beta^{(t)}$ ,  $\mathbf{b}^{(t)}$ ,  $\vartheta^{(t)}$  aus diesen (geg. jeweils die momentan aktuellen Zustände) bis  $T$  erreicht.

Nach einer gewissen Konvergenzphase können die Zufallszahlen als Ziehungen aus den Marginalverteilungen von  $\beta|\mathbf{y}$ ,  $\mathbf{b}|\mathbf{y}$  und  $\vartheta|\mathbf{y}$  angesehen werden.

# Vollständig bedingte Dichten

$$\begin{aligned}
 p(\boldsymbol{\beta} | \mathbf{b}, \boldsymbol{\vartheta}, \mathbf{y}) &\propto p(\mathbf{y} | \boldsymbol{\beta}, \mathbf{b}, \boldsymbol{\vartheta}) p(\boldsymbol{\beta}) \\
 &\propto \exp \left( -\frac{1}{2} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta} - \mathbf{Z}\mathbf{b})' \mathbf{R}(\boldsymbol{\vartheta})^{-1} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta} - \mathbf{Z}\mathbf{b}) \right. \\
 &\qquad \qquad \qquad \left. -\frac{1}{2} (\boldsymbol{\beta} - \mathbf{m})' \mathbf{M}^{-1} (\boldsymbol{\beta} - \mathbf{m}) \right)
 \end{aligned}$$

$$\begin{aligned}
 p(\mathbf{b} | \boldsymbol{\beta}, \boldsymbol{\vartheta}, \mathbf{y}) &\propto \exp \left( -\frac{1}{2} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta} - \mathbf{Z}\mathbf{b})' \mathbf{R}(\boldsymbol{\vartheta})^{-1} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta} - \mathbf{Z}\mathbf{b}) \right. \\
 &\qquad \qquad \qquad \left. -\frac{1}{2} \mathbf{b}' \mathbf{G}(\boldsymbol{\vartheta})^{-1} \mathbf{b} \right)
 \end{aligned}$$

$$\begin{aligned}
 p(\boldsymbol{\vartheta} | \boldsymbol{\beta}, \mathbf{b}, \mathbf{y}) &\propto p(\mathbf{y} | \boldsymbol{\beta}, \mathbf{b}, \boldsymbol{\vartheta}) p(\mathbf{b} | \boldsymbol{\vartheta}) p(\boldsymbol{\vartheta}) \\
 &\propto |\mathbf{R}(\boldsymbol{\vartheta})|^{-1/2} |\mathbf{G}(\boldsymbol{\vartheta})|^{-1/2} \exp \left( -\frac{1}{2} \mathbf{b}' \mathbf{G}(\boldsymbol{\vartheta})^{-1} \mathbf{b} \right. \\
 &\qquad \qquad \qquad \left. -\frac{1}{2} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta} - \mathbf{Z}\mathbf{b})' \mathbf{R}(\boldsymbol{\vartheta})^{-1} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta} - \mathbf{Z}\mathbf{b}) \right) p(\boldsymbol{\vartheta})
 \end{aligned}$$



## Vollständig bedingte Dichten von $\beta$ , $b$

$$\beta|\cdot \sim N(\mu_\beta, \Sigma_\beta) \text{ mit (Übung)}$$

$$\Sigma_\beta = (\mathbf{X}'R(\vartheta)^{-1}\mathbf{X} + \mathbf{M}^{-1})^{-1}$$

$$\mu_\beta = \Sigma_\beta (\mathbf{M}^{-1}\mathbf{m} + \mathbf{X}'R(\vartheta)^{-1}(\mathbf{y} - \mathbf{Z}\mathbf{b}))$$

$$b|\cdot \sim N(\mu_b, \Sigma_b) \text{ mit (analog)}$$

$$\Sigma_b = (\mathbf{Z}'R(\vartheta)^{-1}\mathbf{Z} + \mathbf{G}(\vartheta)^{-1})^{-1}$$

$$\mu_b = \Sigma_b (\mathbf{Z}'R(\vartheta)^{-1}(\mathbf{y} - \mathbf{X}\beta))$$

- **nichtinformative Priori** mit  $\mathbf{M}^{-1} = \mathbf{0}$ : Erwartungswert  $\mu_\beta = (\mathbf{X}'R(\vartheta)^{-1}\mathbf{X})^{-1}\mathbf{X}'R(\vartheta)^{-1}(\mathbf{y} - \mathbf{Z}\mathbf{b})$  ist gewichteter KQ-Schätzer angewandt auf die um  $\mathbf{Z}\mathbf{b}$  bereinigten Daten
- **informative Priori**  $\Rightarrow$  Erwartungswert  $\mu_\beta$  ist gewichtetes Mittel aus KQ-Schätzer und Priori-Erwartungswert.
- Analog für  $\mu_b$ .

## Vollständig bedingte Dichten von $\vartheta$ im Spezialfall

LMM für Clusterdaten mit  $\text{Cov}(\varepsilon) = \sigma^2 I_n \Rightarrow \vartheta$  enthält  $\sigma^2$  und Parameter in  $\mathbf{D}$ .

- nichtinformative Jeffreys Prioris  $p(\sigma^2) \propto \sigma^{-2}$ ,  $p(\mathbf{D}) \propto |\mathbf{D}|^{-\frac{q+1}{2}}$  führen i.A. zu uneigentlichen (d.h. nicht normierbaren) Posteriori-Verteilungen

$\Rightarrow$  Schwach informative inverse Gammaverteilung  $\sigma^2 \sim IG(a_\sigma, b_\sigma)$ ;  $a_\sigma, b_\sigma$  klein

- Für  $\mathbf{D}$  oft inverse Wishart-Verteilung. Bei  $\mathbf{D} = \text{diag}(\tau_1^2, \dots, \tau_q^2)$  mit unabh.  $\tau_j^2$  ergibt diese ein Produkt von IGs mit  $\tau_j^2 \sim IG(a_{\tau_j}, b_{\tau_j}), j = 1, \dots, q$ .

Dann full conditionals bei zusätzlich  $p(\beta) \propto \text{const}$  (nichtinformative Priori):

$$\sigma^2 | \cdot \sim IG(\tilde{a}_\sigma, \tilde{b}_\sigma) \text{ mit } \tilde{a}_\sigma = a_\sigma + \frac{1}{2}, \tilde{b}_\sigma = b_\sigma + \frac{1}{2} \|\mathbf{y} - \mathbf{X}\beta - \mathbf{Z}\mathbf{b}\|_2^2$$

$$\tau_j^2 | \cdot \sim IG(\tilde{a}_{\tau_j}, \tilde{b}_{\tau_j}) \text{ mit } \tilde{a}_{\tau_j} = a_{\tau_j} + \frac{m}{2}, \tilde{b}_{\tau_j} = b_{\tau_j} + \frac{1}{2} \sum_{i=1}^m b_{ij}^2$$

## Probleme der NV-Annahme für $\mathbf{b}$

NV-Annahme für zufällige Effekte  $\mathbf{b} \sim N(\mathbf{0}, \mathbf{G})$  mathematisch günstig. Aber wie sensitiv ist die Schätzung bei Fehlspezifikation?

- Die Schätzer der festen Effekte  $\beta$  und der Kovarianzparameter  $\vartheta$  sind meist sehr robust gegenüber Fehlspezifikation der Verteilung der  $\mathbf{b}$ . Die Standardfehler können jedoch über/unterschätzt werden.
- Durch den Shrinkage-Effekt können die EBLUPs der zufälligen Effekte  $\mathbf{b}$  normalverteilt aussehen, selbst wenn die Verteilung der  $\mathbf{b}$  z.B. bimodal / schief ist / hohe Wahrscheinlichkeitsmasse an den Rändern hat (heavy tails)  $\Rightarrow$  Schlechte Vorhersagen  $\hat{\mathbf{b}}$ . q-q-Plots der  $\hat{\mathbf{b}}$  eignen sich nicht zur Diagnose. Diagnose durch Fitten eines flexibleren Modells.

## Alternative Prioris für $b$ : Skalenmischungen

- Verwendung von Prioris mit mehr Masse auf den Rändern (heavy-tailed): z.B. t-Verteilung mit niedrigen Freiheitsgraden, Laplace-Verteilung. Diese sind oft darstellbar als Skalenmischung von Normalverteilungen

$$p(b_i) = \int \phi(b_i | \mu, \sigma^2) p(\sigma^2 | \theta) d\sigma^2$$

- Darstellbar als Skalenmischung  $\Rightarrow$  sehr leicht in Modellhierarchie für LMM einzubauen
- Beispiel: t-Verteilung mit  $df = \nu$  ist Skalenmischung aus  $N(0, \sigma^2)$  mit  $\sigma^{-2} \sim \Gamma(\nu/2, \nu/2)$

## Alternative Prioris für $b$ : Finite Mixtures

- Zur Aufdeckung von Clustern (z.B. durch unbeobachtete Kovariablen oder latente Subpopulationen) können multimodale Verteilungen für die zufälligen Effekte verwendet werden, z.B. **finite Mischverteilungsmodelle**:

$$p(\mathbf{b}_i | \boldsymbol{\pi}, \boldsymbol{\phi}) = \sum_{k=1}^K \pi_k p(\mathbf{b}_i | \boldsymbol{\phi}_k),$$

mit Gewichten  $\boldsymbol{\pi} = (\pi_1, \dots, \pi_K)$ ,  $\sum_k \pi_k = 1$ , und parametrischer Verteilungsfamilie  $p(\mathbf{b}_i | \boldsymbol{\phi}_k)$  mit Parametern  $\boldsymbol{\phi} = (\boldsymbol{\phi}_1, \dots, \boldsymbol{\phi}_K)$  (z.B. multivariate NV  $p(\mathbf{b}_i | \boldsymbol{\mu}_k, \boldsymbol{\Sigma})$  mit Erwartungswerten  $\boldsymbol{\mu}_k$  und homogenen Kovarianzen  $\boldsymbol{\Sigma}$ )

- nichtparametrische Erweiterung:  $K$  nicht fest/konstant, wird mitgeschätzt.
- Noch flexibler: nichtparametrische Bayes-Ansätze, z.B. **Dirichlet-Prozess**, Dirichlet-Prozess-Mischungs-Prioris.
- Inferenz für diese Modelle basiert i.d.R. auf MCMC-Techniken.