

# (Zobecněné) lineární smíšené modely

0

→ částečně opakování z pokročilých regresních modelů

## 1. Lineární smíšený model

1

- měřena' kvantitativně jiná než v PRM

2

+  $E b_i = \mu$  ( $\equiv$  průměrná projevů efektů)

$$Y_i = X_i \beta + Z_i b_i + \epsilon_i, \quad i=1, \dots, N$$

$\overline{mix}$   $\overline{mix}$   
přísl. matice

$$b_i \stackrel{iid}{\sim} N_q(\mu, D)$$

$$\epsilon_i \sim N_{m_i}(0, \Sigma_i)$$

$b_1, \dots, b_N, \epsilon_1, \dots, \epsilon_N$  nezávislé

"skutečné" parametry modelu:

$$\psi = (\beta, \mu, D, \text{parm}(\Sigma_i))$$


obvykle  $\Sigma_i = \sigma^2 I_{m_i}$   $\forall i$

### LMM hierarchický

3

$$Y_i | b_i, \beta, \Sigma_i \stackrel{nezav.}{\sim} N_{m_i}(X_i \beta + Z_i b_i, \Sigma_i)$$

$$b_i | \mu, D \stackrel{iid}{\sim} N_q(\mu, D)$$



7

## 2. Příklady LMM

4

### Příklad 1 „ANOVA“ LMM

5

$$Y_{ij} = b_i + \varepsilon_{ij} \quad , \quad E b_i = \mu \quad , \quad \text{var } b_i = d^2$$

$$i = 1, \dots, N \quad , \quad E \varepsilon_{ij} = 0 \quad , \quad \text{var } \varepsilon_{ij} = \sigma^2$$

$$j = 1, \dots, n_i \quad , \quad \Sigma_i = \sigma^2 I_{n_i}$$

### Příklad 2 $Y_{ij}$ = PCV příněstek u $j$ -té larány $i$ -tého stáda

6


stádo 1



stádo 2



stádo 3



obrázky 7 - 8

(a) dávka má stejný účinek ve všech stádech

$$Y_{ij} = b_i + \varepsilon_{ij} \quad , \quad \text{pokud LOW}$$

$$= b_i + \beta + \varepsilon_{ij} \quad , \quad \text{pokud HIGH}$$

9

$$Y_{ij} = b_i + \beta x_{ij} + \varepsilon_{ij} \quad , \quad x_{ij} = \begin{cases} 0 & \text{LOW} \\ 1 & \text{HIGH} \end{cases}$$

$$E b_i = \mu \quad , \quad \text{var } b_i = d^2$$

$$E \varepsilon_{ij} = 0 \quad , \quad \text{var } \varepsilon_{ij} = \sigma^2$$

$$Y_i = X_i \beta + Z_i b_i + \varepsilon_i \quad , \quad \text{var } \varepsilon_i = \sigma^2 I_{n_i}$$

$Z_i$

$$X_i = \begin{pmatrix} 0 \\ \vdots \\ 0 \\ 1 \\ \vdots \\ 1 \end{pmatrix} \quad , \quad Z_i = \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{pmatrix}$$

11

(b) dařka funguje relativně v různých stádech [12]

→ efekt dařky ( $\beta$ ) závisí na  $i$

$$Y_{ij} = b_{i,1} + b_{i,2} z_{ij} + \varepsilon_{ij}$$

$z_{ij} \equiv x_{ij}$  v předch. případě

$$E \begin{pmatrix} b_{i,1} \\ b_{i,2} \end{pmatrix} = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix} = \beta \text{ v předchozím}$$

$$\text{var} \begin{pmatrix} b_{i,1} \\ b_{i,2} \end{pmatrix} = D, \quad \text{var} \varepsilon_{ij} = \sigma^2$$

13  
14

Příklad 3: Longitudinální data

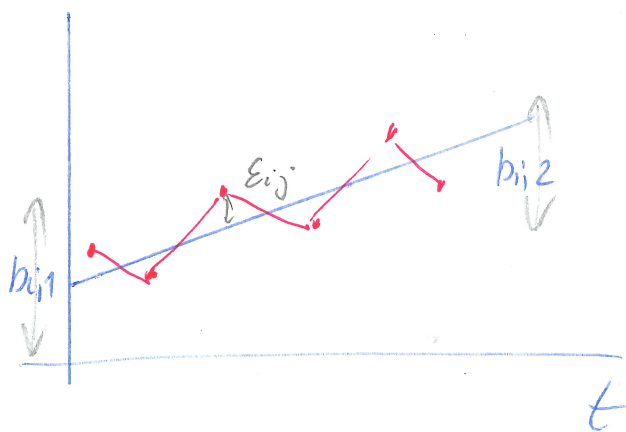
15

obrázek

16

MODEL? lineární trend pro každého pac.

17



18

2 skupiny - liší se STŘEDNÍ HODN.  
směrnicí.

19

$\beta$  = rozdíl středních směrnic

20

$$X_i = \begin{pmatrix} t_{i1} \\ \vdots \\ t_{mi} \end{pmatrix}, \text{ pokud } x_{ij} = x_i = 1$$

$$= \begin{pmatrix} 0 \\ \vdots \\ 0 \end{pmatrix}, \text{ pokud } x_{ij} = x_i = 0$$

$$Z_i = \begin{pmatrix} 1 & t_{i1} \\ \vdots & \vdots \\ 1 & t_{mi} \end{pmatrix}$$

$$\Sigma_i = \sigma^2 I_{m_i}$$


### 3. Lineární smíšený model bayesovský

22

opakuje se...

23

(1) (2)  $\equiv$  hierarchický model



$$y_i | b_i; \beta, \Sigma_i \stackrel{\text{nezav.}}{\sim} \mathcal{N}_{m_i}(X_i \beta + Z_i b_i, \Sigma_i)$$

$$b_i | \mu, D \stackrel{\text{i.i.d.}}{\sim} \mathcal{N}_q(\mu, D)$$

obvykle  $\Sigma_i = \sigma^2 I_{m_i}$

24

"skutečné" parametry:

$$\psi \equiv (\beta, \sigma^2, \mu, D)$$

$$L_F(\psi) = p(y | \psi) = \int p(y | b, \psi) p(b | \psi) db =$$

25

$$= \prod_{i=1}^N \int p(y_i | b_i, \psi) p(b_i | \psi) db_i \stackrel{\text{integral umíme}}{=} \\ \underbrace{w(\dots)} \cdot \underbrace{w(\dots)}$$

$$= \prod_{i=1}^N \varphi(y_i | X_i \beta + Z_i \mu, V_i)$$

$$V_i = Z_i D Z_i^T + \Sigma_i$$

- teď by stačilo specifikovat apriorní  $p(\psi)$  pro  $\psi$  a můžeme odvozovat aposteriorní model,

$$p(\psi | y) \propto \underbrace{p(y | \psi)}_{L_F(\psi)} p(\psi)$$

Pro Bayes. počítání:

$$(b_1, \dots, b_N) \equiv \xi \quad (\text{skrytá data})$$

→ další „parametry“ modelu

věrohodnost pro Bayes. počítání:

$$\begin{aligned} L(\xi, \psi) &= p(y | \xi, \psi) = \prod_{i=1}^N p(y_i | b_i, \psi) \\ &= \prod_{i=1}^N \varphi(y_i | x_i \beta + z_i b_i, \Sigma_i) \end{aligned}$$

apriorní nádel:

$$\begin{aligned} p(\xi, \psi) &= p(\xi | \psi) p(\psi) \\ &= \prod_{i=1}^N p(b_i | \psi) p(\psi) \\ &= \prod_{i=1}^N \varphi(b_i | \mu, D) p(\psi) \end{aligned}$$

$$\rightarrow p(\xi, \psi | y) \propto \underbrace{p(y | \xi, \psi)}_N \underbrace{p(\xi | \psi)}_N \underbrace{p(\psi)}_{\text{nutro-nejak volit}}$$

hierarchický princip  
=>

$$p(\psi | y) = \int p(\xi, \psi | y) d\xi$$

(z minimální strany)

## 4. Zobecněný lineární smíšený model

27

Generalized linear mixed model - GLMM

Příklad: opěť myši

28

$$Y_{ij} = \begin{cases} 0 & \text{j-ty' zavrtek i-te' myši BÉZ rady} \\ 1 & \text{S radou} \end{cases}$$

Primární cíl: inference o  $\pi = E Y_{ij} = P(Y_{ij}=1)$

obrazek

29

MOŽNÝ MODEL 1:  $Y_{ij} \stackrel{iid}{\sim} A(\pi)$   
↓ asin...

30

MOŽNÝ MODEL 2 (hierarchický)

pro myš  $i$ :  $P(Y_{ij}=1) = \pi_i$

$\eta$ :  $Y_{ij} | \pi_i \sim A(\pi_i)$

$\pi_i \stackrel{iid}{\sim} \text{modelu' na } (0,1)$   
(s parametry  $\psi$ )

$0 < \pi_i < 1$  omezení jsou obtížná...

→ reparametrizuj

$$b_i = \text{logit } \pi_i = \log\left(\frac{\pi_i}{1-\pi_i}\right)$$

$$\eta: \pi_i = \frac{e^{b_i}}{1+e^{b_i}}$$


$\pi_i \stackrel{iid}{\sim} \text{model. na } (0,1) \Leftrightarrow b_i \stackrel{iid}{\sim} \text{model. na } \mathbb{R}$

→ logistická regrese s náhodnými efekty

7

# Logistická regrese s náhodným interceptem

Hierarchický model:



$$Y_{ij} | b_i \sim A(\bar{y}_i) \quad \bar{y}_i = \frac{e^{b_i}}{1 + e^{b_i}}$$

$$b_i \stackrel{i.i.d.}{\sim} \mathcal{N}(\mu, d^2)$$

máři.  $\psi$ : "skutečné" parametry

$$P(y | B) = \prod_{i=1}^N P(y_i | b_i) = \prod_{i=1}^N \prod_{j=1}^{m_i} P(y_{ij} | b_i)$$

$\bar{y}_i^{y_{ij}} (1 - \bar{y}_i)^{1 - y_{ij}}$

$$B = (b_1, \dots, b_N)$$

$$P(B | \underbrace{\mu, d^2}_{\psi}) = \prod_{i=1}^N P(b_i | \mu, d^2) \sim \mathcal{N}(\mu, d^2)$$

$$L(y) = P(y | \psi) = \int P(y | B, \psi) P(B | \psi) dB =$$

$$= \prod_{i=1}^N \int P(y_i | b_i) P(b_i | \psi) db_i =$$

$$= \prod_{i=1}^N \int \prod_{j=1}^{m_i} P(y_{ij} | b_i) P(b_i | \psi) db_i =$$

$$= \prod_{i=1}^N \int_{\mathbb{R}} \frac{e^{b_i (\sum_j y_{ij})}}{(1 + e^{b_i})^{m_i}} \varphi(b_i | \mu, d^2) db_i$$

↳ good luck

Bayesovský předpoklad  $P(y)$ , pracuj s

$$P(B, y | \psi) \propto P(y | B, \psi) P(B | \psi) P(y)$$

$$= \prod_i \left( \prod_j P(y_{ij} | b_i) \right) P(b_i | \psi) P(y)$$

8) žádný integrál  
i když pozor, stále nějaké normující konstanty!



# GLMM obecně

$Y_{ij} | b_i \sim$  exponenciální třída,  $i=1, \dots, N$   
 $Y_{ij} | b_i$  nezávislé pro  $j=1, \dots, n_i$ ,  $j=1, \dots, n_i$

$$E(Y_{ij} | b_i) = h(\underbrace{x_{ij}^T \beta}_{\uparrow \text{inverzní linka}} + \underbrace{z_{ij}^T b_i}_{\rightarrow \text{vektory konstant}}) =: \mu(b_i)$$

$$\text{var}(Y_{ij} | b_i) = \Phi V(\mu(b_i)), \quad \Phi = \text{dispersionní param.}$$

často  $\Phi = 1$

Pozn. v LMM  $\Phi = \sigma^2$   
 = (reziduální)  
 nezávisle pro  $E_{ij}$

$$b_i \sim N(\mu, D)$$

primární (skutečné) parametry  $\psi = (\beta, \Phi, \mu, D)$

skrytá data:  $\xi \equiv B = (b_1, \dots, b_N)$  často nemí

Pouze "drobné" modely oproti LMM:

$$p(\psi | B, \psi) = \prod_{i=1}^N p(y_i | b_i, \psi) =$$

$$= \prod_i \prod_j p(y_{ij} | b_i, \psi) \stackrel{\text{LMM}}{=} \prod_i \prod_j \varphi(y_{ij} | \dots)$$

hustota exponenciální třídy, osov.  $g(\cdot | \mu(b_i), \Phi)$

$\sim N(x_{ij}^T \beta + z_{ij}^T b_i, \sigma^2)$   
 $\mu(b_i)$

Věrohodnost pro frekventistické výpočty

$$\begin{aligned} L(\psi) &= p(y|\psi) = \int p(y|B, \psi) p(B|\psi) dB = \\ &= \prod_i \int p(y_i | b_i, \psi) p(b_i | \psi) db_i = \\ &= \prod_i \int_{\mathbb{R}^D} \prod_j g(y_{ij} | \mu(b_i), \sigma) \varphi(b_i | \mu, D) db_i \end{aligned}$$

*typicky nelze analyticky ...*

Bayesovský předej  $p(\psi)$ , pracuj s

$$\begin{aligned} p(B, \psi | y) &\propto p(y|B, \psi) p(B|\psi) p(\psi) \\ &= \prod_i \left( \prod_j p(y_{ij} | b_i, \psi) \right) p(b_i | \psi) p(\psi) \end{aligned}$$

Zádný integrál,  
ale nesnáme normující konstantu,  
takže ani přímá simulace  
nemí šanci!

→ MCMC (předej)

# 5. Apriornu' rozdelem'

pro LMM / GLMM

32

33

$$\psi = (\beta, \mu, \tau, \Omega)$$

↑  
globálne efekty

←  
str. hodnoty  
nač. efekty

$$\tau = \phi^{-1}$$

= inverzná disperz.  
param

$$= \sigma^{-2} \text{ v LMM}$$

## Prípomínka:

$Y_{ij} | b_i \sim \text{exp. trída}(\mu(b_i), \phi)$

$$\mu(b_i) = h(x_{ij}^T \beta + z_{ij}^T b_i)$$

$$b_i \sim \text{i.i.d. } N(\mu, D)$$

$\Omega = D^{-1}$  = inverzná  
var. matice nač.  
efektu

$$\xi = B = (b_{i1}, \dots, b_{in})$$

$$p(\xi, \psi) = p(\xi | \psi) p(\psi)$$

viz model =  $\prod_i p(b_i | \psi)$   
 $\sim N(\mu, D)$

Nymi': jak volit  $p(\psi)$ ?

$p(\psi)$ : prípadne tiež hierarchický

$$p(\psi) = \int p(\psi | \xi) p(\xi) d\xi$$

$\xi$ : hyperparametry (= ďalší param. modelu)

$$p(\xi, \psi, \xi) = p(\xi | \psi) p(\psi | \xi) p(\xi)$$

jak tohle?

34

41

prešloc'

35

$$\psi = (\beta, \mu, \tau, \Omega)$$

$$\tau = \Phi^{-1}$$
$$\Omega = D^{-1}$$

36

VOLBA  $p(\psi)$ , resp.  $p(\psi|\xi)$ :

obvyklý postup: apriorní nezávislost pro sady „různých“ param.

$$\rightarrow p(\psi) = p(\beta, \mu, \tau, \Omega) = p(\beta) p(\mu) p(\tau) p(\Omega)$$

resp.

$$p(\psi|\xi) = p(\beta|\xi^{(1)}) \cdot p(\mu|\xi^{(2)}) \cdot p(\tau|\xi^{(3)}) p(\Omega|\xi^{(4)})$$

•  $\beta, \mu \equiv$  střední hodnota

37

VOLBA 1

$$p(\beta) \propto 1 \quad \text{y} \quad \text{POZOR, nevláhu!}$$
$$p(\mu) \propto 1$$

VOLBA 2

$$p(\beta) \sim N(\beta_0, \Sigma_0^\beta)$$

$$p(\mu) \sim N(\mu_0, \Sigma_0^\mu)$$

pevně / ma'hodně hyperparam.

potud pevně:

napi.  $\beta_0 = 0$  y kromě abs. členů modelu  
 $\mu_0 = 0$

$\Sigma_0^\beta, \Sigma_0^\mu$ : diag. matice,  
„velká“ diagonála

$$\tau = \phi^{-1} \quad (\text{např. } \sigma^{-2} \text{ a LMM})$$

= inverzní "rozptyl"

VOĽBA:  $p(\tau) \sim \text{Ga}(c_\tau, d_\tau)$

perné / náhodné hyperparam.

↙  
mj. registuje

$$P(\tau > 0 | \mathcal{Y}) = 1$$

• jak volit  $c_\tau, d_\tau$ ?

-  $c_\tau \equiv$  stupně volnosti

$c_\tau \in (0, 1]$ : slabě informovaní rozděl.

-  $E\tau = \frac{c_\tau}{d_\tau}$ ,  $\text{var } \tau = \frac{c_\tau}{d_\tau^2}$

$d_\tau > 0$ : "přímot"

$d_\tau \rightarrow 0$ : slabě informovaní

- empirické studie:

aposteriorní rozdělenní byva' citlivé na volbu  $d_\tau$

→  $d_\tau$  často náhodný hyperparam.

$$d_\tau \sim \text{Ga}(\cdot, \cdot)$$

↙  
jako perné

- často volby (pokud  $c_\tau$  i  $d_\tau$  perné):

$$\tau \sim \text{Ga}(1, 0,005)$$

$$\sim \text{Ga}(0,001, 0,001)$$

•  $Q = D^{-1}$ ,  $D = \text{var } b_i$

39

- potřeba vícerozměrné rozdělení, které s.j. generuje pozitivně definitní matici

→ Wishartovo rozdělení

Wishartovo rozdělení

40

≡ zobecnění  $\chi^2$

$Q \sim W_p(\nu, \Sigma) \Leftrightarrow Q = \sum_{i=1}^{\nu} Z_i Z_i^T$

•  $Z_i \text{ i.i.d. } N_p(0, \Sigma)$

•  $\nu > p-1$  : stupně volnosti

→ příjme :  $P(Q > 0) = 1$

"SDC" : odvod hustoty Wishartova rozdělení [41]

→ lze uvažovat křivě necelobíselné stupně voln.

•  $E Q = \nu \Sigma$

•  $W_1(\nu, 1) \equiv \text{Ga}(\frac{\nu}{2}, \frac{1}{2}) \equiv \chi^2_{\nu}$

•  $W_1(\nu, \Sigma) \equiv \text{Ga}(\frac{\nu}{2}, \frac{\Sigma^{-1}}{2})$   
↑ skalár

$\nu, \Sigma$  : hyperparametry < neznámé náhodné

42

obvyklé volno :  $\nu \in (p-1, p]$

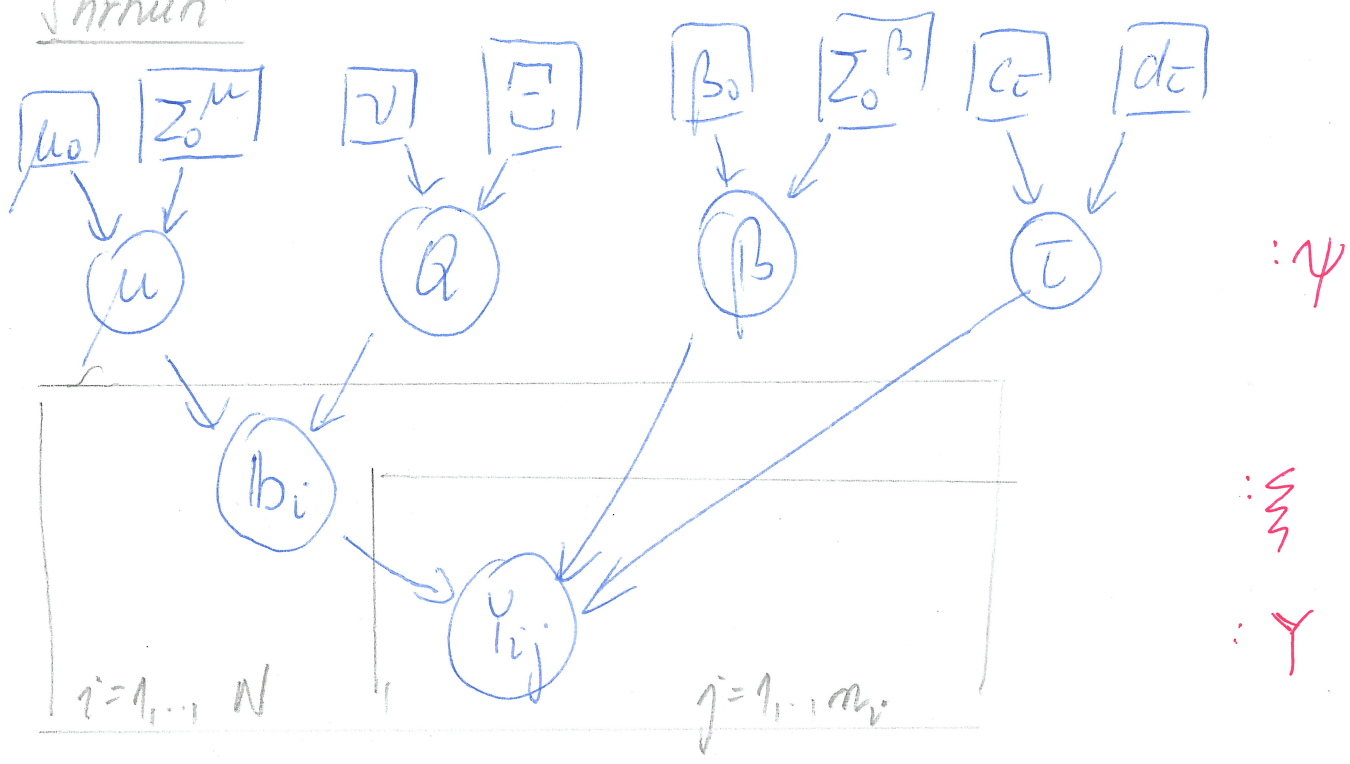
$\Sigma^{-1} = \text{diag}(\underbrace{\mu_1, \dots, \mu_p}_{\text{malá } (\rightarrow 0)})$

případně :  $\mu_j \sim \text{Ga}(\cdot, \cdot)$

} motivace jako u  $\bar{c}$

147

Shrnuti'



6. Aposteriornu' rozdeleni'

viz hierarchicka' struktura, resp. DAG

$$\begin{aligned}
 P(\xi, \psi | y) &\propto p(y | \xi, \psi) p(\xi | \psi) p(\psi) \\
 &= \prod_i \prod_j p(y_{ij} | b_i, \beta, \tau) \cdot \prod_i p(b_i | \mu, Q) \\
 &\quad \cdot p(\mu) p(Q) p(\beta) p(\tau)
 \end{aligned}$$

prípadne

$$\begin{aligned}
 p(\xi, \psi, \xi | y) &\propto p(y | \xi, \psi) p(\xi | \psi) p(\psi | \xi) p(\xi) \\
 &= \prod_i \prod_j p(y_{ij} | b_i, \beta, \tau) \prod_i p(b_i | \mu, Q) \\
 &\quad \cdot p(\mu | \xi^{(1)}) p(Q | \xi^{(2)}) p(\beta | \xi^{(3)}) \\
 &\quad \cdot p(\tau | \xi^{(4)})
 \end{aligned}$$

! nezabudne normaliza' konstanta

Díky hierarchické struktuře se zplati

46

$$p(\psi|\mathcal{Y}) = \int p(\psi, \xi|\mathcal{Y}) d\xi \leftarrow \text{traj bez}$$
$$= L_F(\psi) p(\psi), \text{ kde}$$

náhod.  
hyperparam.

$$L_F(\psi) = p(\mathcal{Y}|\psi) = \int \int \int p(\mathcal{Y}|\xi, \psi) p(\xi|\psi) d\xi$$

B                    B                    B

7. Inference založena na aposteriorním rozdělení

47

provádáme

48-50

→ bude: MCMC

Markov chain Monte Carlo

→ generuj Markovův řetězec

$\theta^{(1)}, \theta^{(2)}, \dots, \theta^{(M)}$  takový, že  
jeho stacionární rozdělení

je  $p(\theta|\mathcal{Y})$

(resp. rozdělení, k němuž  
bých měl náhodný  
výběr)