

Příklad 4: (Intervalové) cenzování

Chci pozorovat $T_i \in \underbrace{(L_i, U_i]}_{\text{data}}, i=1, \dots, n$

$$0 \leq L_i < U_i \leq \infty, \quad U_i = \infty \equiv \text{cenzor. zpráva}$$

model pro T_i :

$F_i(\cdot; \theta) \equiv$ distrib. fce, kterou předpokl. pro T_i

• nesávidlé, neinformativní cenzování

$$L_{\text{obs}}(\theta) = \prod_{i=1}^n P(L_i < T_i \leq U_i; \theta) =$$

$$= \prod_{i=1}^n (F_i(U_i; \theta) - F_i(L_i; \theta)) \quad \checkmark =$$

$$= \prod_{i=1}^n \int_{L_i}^{U_i} f_i(t; \theta) dt$$

$f_i \equiv$ hustota pro F_i

VIDĚNĚ:

$L(y|\theta) = P(y|\theta)$ ne vždy "hesla"¹

řešení: uvažuj DOPLNĚNÁ (AUGMENTED)
data \equiv latentní data

motivace - hierarchický model

$$P(y|\theta) = \int P(y|\psi, \theta) P(\psi|\theta) d\psi$$

↑ 2. úroveň "data"
(např. náhodné efekty
ve smíř. modelu)

pro bayes. počítání (na základe MC (MCMC))

$(\psi, \theta) =$ parametry

"věrohodnost" pro Bayes. větu byla

$$P(y|\psi, \theta) =: \text{Langmu}(\psi, \theta)$$

\equiv doplněná věrohodnost

BYLO: $P(\psi, \theta) = P(\psi|\theta) \cdot P(\theta)$

muselo odpovídat
původnímu modelu

$\Rightarrow P(\theta|y)$ bylo marginální
určeno z $P(\theta, \psi|y)$

$$P(\theta, \psi|y) \propto \underbrace{P(y|\psi, \theta)}_{\text{Langmu } (\psi, \theta)} \underbrace{P(\psi, \theta)}_{P(\psi|\theta)P(\theta)}$$

Langmu (ψ, θ) $P(\psi|\theta)P(\theta)$

BDA (Bayesian data augmentation)
obecně

$P(y|\theta)$ data a je "nehezka"
(věrohodnost, model)

BDA: namícháme ψ / doplnění /

augmented) data ~~at~~,
atq a k nim

$P(y|\psi, \theta)$, $P(\psi|\theta)$ / 2 data /
model,

pokřeba ude lat ~~at~~, atq

$$P(y|\theta) = \int P(y|\psi, \theta) P(\psi|\theta) d\psi$$

(Pocit) stejně jako výše bude

$$P(\theta | y) = \int P(\theta, \psi | y) d\psi \quad \vee$$

Bayes. modelu s a priori

$$P(\theta, \psi) = P(\theta) \underline{P(\psi | \theta)} \underline{P(y)}$$

aby bylo prakticky užitečné, je potřeba,

aby $P(y | \psi, \theta)$ i $P(\psi | \theta)$

bylo "hezke"

Příklady:

1) LMM, mohlo by začít s h'm. i

model =

$$P(y_i | \theta) = \mathcal{N}(X_i \beta + Z_i \mu, \quad \mu$$

$$\underbrace{Z_i D Z_i^T + \sigma^2 I_{m_i}}_{\text{musí být } \geq 0}$$

musí být ≥ 0

2) Logistická regrese o náh. efekty

$$P(y_i | b_i, \theta) \equiv \text{dopln. v\u011brohodnot\u011b}$$

$$= \prod_{j=1}^{n_i} P(y_{ij} | b_i, \theta) \sim \text{Alt}\left(\frac{e^{b_i}}{1 + e^{b_i}}\right)$$

3) mmes

$$L_{\text{obs}}(\theta) = P(y | \theta) = \prod_i \left(\sum_k w_k f_k(y_i; \theta) \right)$$

$$\text{m\u00fd: } f_k \equiv \mathcal{N}(\mu_k, \Sigma_k)$$

\u010dil: navrhmi ψ tak, aby

$P(y_i | \psi_i, \theta)$ bylo bez sou\u010dny

$P(\psi_i | \theta)$ bylo "hezk\u00e9" (θ^2)

a aby platilo

$$P(y_i | \theta) = \int P(y_i | \psi_i, \theta) P(\psi_i | \theta) d\psi_i$$

$$= \sum_k \underbrace{P(y_i | \psi_i = k_i, \theta)}_{f_k(y_i; \theta)} \underbrace{P(\psi_i = k_i | \theta)}_{w_k}$$

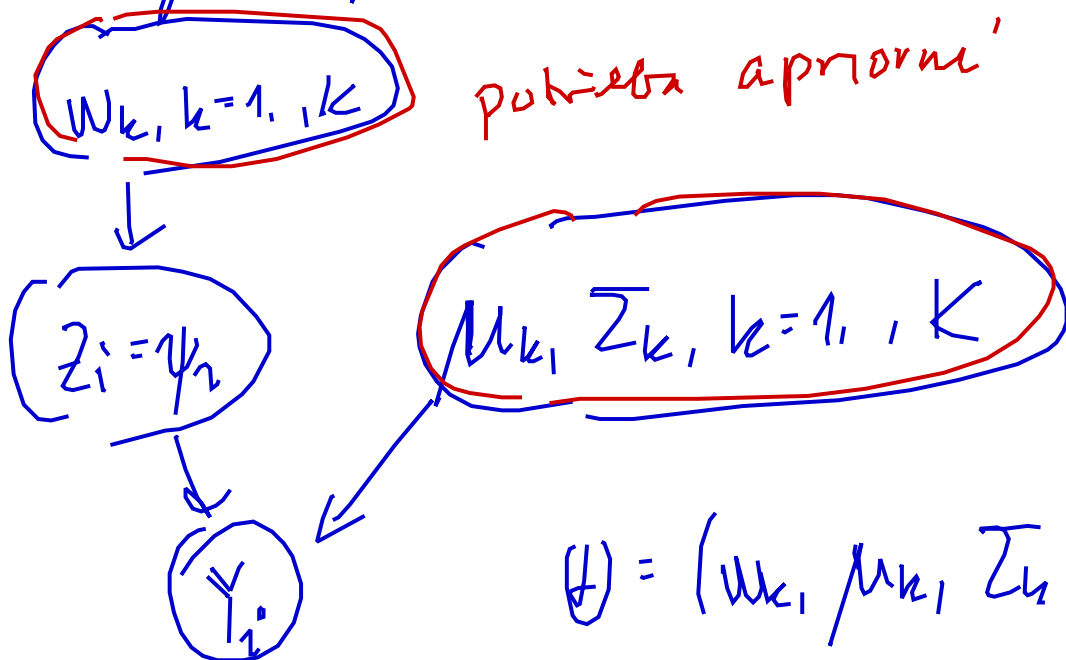
BDA: $\psi = (\psi_{11}, \dots, \psi_m)^\top$
 $\psi_i \equiv Z_i, k \in \{1, \dots, K\}$ $P(Z_i = k | \theta) = w_k$
 $\underbrace{\hspace{10em}}_{= P(\psi_i | \theta)}$

$$P(\psi_i | \psi_i = k, \theta) \equiv f_k(\psi_i; \theta) \equiv N(\mu_k, \Sigma_k)$$

$$P(\theta, \psi | y) \propto P(y | \theta, \psi) P(\psi | \theta) P(\theta) =$$

$$= \prod_{i=1}^n \underbrace{P(\psi_i | \psi_i, \theta)}_{f_{\psi_i}(\psi_i; \theta)} \underbrace{P(\psi_i | \theta)}_{w_{\psi_i}} P(\theta)$$

Bayes, algorithm' \rightarrow hierar. model



Gibbs! $P(\theta | \dots) \propto$

$$\propto \prod_{i=1}^n P(y_i | z_i, \underbrace{\mu_k, \Sigma_k}_{k=1, \dots, K}) P(z_i | \underbrace{w_k}_{k=1, \dots, K}) \cdot P(\theta)$$

$$P(\underbrace{\mu_k, \Sigma_k}_{k=1, \dots, K} | \dots) \propto \underbrace{P(y_i | \mu_k, \Sigma_k, z_i)}_{k=1, \dots, K} \cdot \underbrace{P(\mu_k, \Sigma_k)}_{k=1, \dots, K}$$

$$\equiv N(\mu_{z_i}, \Sigma_{z_i})$$

BUDE SNADNE, pokud $P(\mu_k, \Sigma_k)$ je (semi) konjugovane k normalnimu rozdeleni

$$P(w_k | \dots) \propto \prod_{i=1}^n \underbrace{P(z_i | w_k)}_{k=1, \dots, K} P(w) =$$

$$\boxed{z_i \in \{1, \dots, K\}}$$

$$= \prod_{i=1}^n w_{z_i} \cdot \underline{P(w)}$$

konjugovani, zdel je Dirichletovo rozd. /

- a) pouze 2 skupiny
 $w = (w_1, w_2)$
 $\equiv (w, 1-w)$

$$P(w) = \text{Beta}(a, b)$$

$$P(w) \propto w^{a-1} (1-w)^{b-1}$$

b) $K > 2$

$$P(w) = \text{Dirichlet}(a_1, \dots, a_K)$$

$$P(w) \propto w_1^{a_1-1} w_2^{a_2-1} \dots w_K^{a_K-1}$$

$$P(w | \dots) \propto \prod_{i=1}^n w_{z_i} P(w) =$$

$$= \frac{N_1}{w_1} \dots \frac{N_K}{w_K}$$

$$N_k = \sum_{i=1}^n \mathbb{1}(z_i = k)$$

$$\stackrel{\text{E}}{=} \text{Dirichlet}(a_1 + N_1, a_2 + N_2, \dots, a_K + N_K)$$

$$P(z_i | \dots) = ?$$

$$\underbrace{P(z_i = k | \dots)} \propto P(z_i = k | w) \cdot P(y_i | z_i = k, \theta) =$$

$$= \underline{w_k} \cdot f_k(y_i; \mu_k, \Sigma_k)$$


$$P(Z_i = k | \dots) = \frac{w_k f_k(y_i; \mu_k, \Sigma_k)}{\sum_e w_e f_e(y_i; \mu_e, \Sigma_e)}$$

↓ lze použít ke klasifikaci

$Z_i | \dots$ má diskrétní rozdělenní
na $\{1, \dots, K\}$

$$P(Z_i = k | \dots) =$$

Je generován z disk. rozdělení; každý má w generátor z $U(0,1)$.



Cela má jake rozdělenní

DATA \equiv jednotky z K populací

V každé populaci platí obecní jímý model,
merrim, kdo kme patří

$$y_i, i=1, \dots, n$$

celkový model \equiv směs modelů

$$P(y_i | \theta) = \sum_{k=1}^K w_k P_k(y_i | \theta)$$

model pro y_i ,
pokud patří do k -té
populace