

Hierarchické modely

0

1. Hierarchické apriorní rozdělení

1

2

MODEL PRO DATA \equiv věrohodnost

3

$$L(\psi) = p(y|\psi)$$

APRIORNÍ ROZDĚLENÍ: $p(\psi)$

- typicky voleno z nějaké třídy, např. konjugovaných apriorní rozdělení, tj:


$$p(\psi) = p(\psi; \xi)$$

hyperparametr,
pohyba rozličit

Příklad: MODEL & DATA: $y_1, \dots, y_n \text{ i.i.d. } N(\mu, \sigma^2)$
znám

$$\psi \equiv \mu$$

APRIORNÍ: $\mu \sim N(\mu_0, \sigma_0^2)$



μ_0 má být $0, 1, 8, \pi, \dots$?

σ_0 má být $0, 1, 1, 3, 10, 10^8$?

dalsí rozdělení na tyto volby

→ hierarchicky specifikované apriorní

17

Def 3.1 Bayesovský model s hierarchickým specifikovaným - apriorním modelům [4]

• jednodušejí

MODEL: $L(\psi) = p(y|\psi)$

APRIORNI PRO ψ : $p(\psi; \xi)$

$\rightarrow p(\psi|\xi) \approx p(\xi)$

Potom


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

\equiv rozklad variability $p(\psi)$ na


(i) variabilitu $p(\psi|\xi)$

(ii) variabilitu $p(\xi)$

Příklad



\rightarrow



Def 3.1

4

apriorní rozdělání pro ψ :

$$\psi \rightarrow \xi_1 \rightarrow \xi_2 \rightarrow \dots \rightarrow \xi_m$$

sdrůžení:

$$p(\psi, \xi_1, \dots, \xi_m) = p$$

✗ pořadí je definice

$$= p_0(\psi / \xi_1, \xi_2, \dots, \xi_m) \cdot p_1(\xi_1 / \xi_2, \xi_3, \dots, \xi_m)$$

$$\dots p_{m-1}(\xi_{m-1} / \xi_m) \cdot p_m(\xi_m)$$

příslušné marginální je

$$p(\psi) = \int_{z_1 \times \dots \times z_m} p_0(\psi / \xi_1) \cdot p_1(\xi_1 / \xi_2) \cdot \dots \cdot p_{m-1}(\xi_{m-1} / \xi_m) \cdot p_m(\xi_m) d\xi_m \dots d\xi_1$$

ξ_i = hyperparametr i -té úrovně

příslušné aposteriorní rozdělání:

$$p(\psi / y) \propto p(y / \psi) \cdot p(\psi) =$$

$$= p(y / \psi) \int p_0(\psi / \xi_1) \cdot p_1(\xi_1 / \xi_2) \cdot \dots \cdot p_m(\xi_m) d\xi_m \dots d\xi_1$$

Data \equiv nejvyšší (nejnižší) hierarchická úroveň

$$y \xrightarrow{\substack{\uparrow \\ \text{věrohodnost}}} \psi \rightarrow \xi_1 \rightarrow \xi_2 \rightarrow \dots \rightarrow \xi_m$$

$$P(y | \psi, \xi_1, \dots, \xi_m) = P(y | \psi)$$

\uparrow předpoklad (hierarchický model)

$$p(\psi, \xi_1, \dots, \xi_m | y) = ?$$

$$\propto p(y | \psi, \xi_1, \dots, \xi_m) \cdot \underbrace{p(\psi, \xi_1, \dots, \xi_m)}_{\text{hierar. prior}} =$$
$$= p(y | \psi) \cdot p_0(\psi | \xi_1) \cdot p_1(\xi_1 | \xi_2) \dots p_m(\xi_m)$$

Potom $p(\psi | y) = \int p(\psi, \xi_1, \dots, \xi_m | y) d\xi_m \dots d\xi_1$

$$= \int p(y | \psi) p_0(\psi | \xi_1) p_1(\xi_1 | \xi_2) \dots$$

$\dots p_m(\xi_m) d\xi_m \dots d\xi_1$

= minulá strana

Zapamatuj: V hierarchickém apriorním rozdělení je $p(\psi | y)$ marginálním rozdělením a

$$p(\psi, \xi_1, \dots, \xi_m | y)$$

aposteriorní, kde $\Theta = (\psi, \xi_1, \dots, \xi_m)$

pro parametry modelu

Lejměna pro Monte Carlo (Markov chain) může být výhodnější pracovat přímo s \dots

Řejména pro Monte Carlo (Markov chain) může být
(retina je) ^{vychodně} V Macovak primárně \propto

$$p(\psi, \xi_1, \dots, \xi_m | y) \propto$$

$$\propto p(y | \psi) p_0(\psi | \xi_1) p_1(\xi_1 | \xi_2) \dots p_m(\xi_m)$$



a integrál $p(\psi | y) = \int \boxed{} d\xi_m \dots d\xi_1$

prítat pouze když to je skutečně
potřeba (při MC málokdy ...)

→ potřebuji (náhodný) výběr $\propto p(\psi | y)$
 \equiv příslušné složky (náhodného)
výběru $\propto p(\psi, \xi_1, \dots, \xi_m | y)$

Príklad: Lineárny model

5

$Y | \gamma \sim N(X\beta, \sigma^2 I_n)$, $X_{n \times k}$: matice konstant

$$\gamma = (\beta, \tau), \tau = \sigma^{-2}$$

Konjugované a priori rozdelení

$$p(\beta, \tau | \xi) = p(\beta | \tau, \xi) p(\tau | \xi)$$

$$\beta | \tau, \xi \sim N(\beta_0, \tau^{-1} \Sigma_0)$$

$$\tau | \xi \sim \text{Gamma}(c_0, d_0)$$

$$\xi = \underline{\beta_0, \Sigma_0, c_0, d_0}$$

→ ne vše musíme hned snažiť odhadovať

• napí. pouze do na'hodný typu paramete

β_0, Σ_0, c_0 : pevné hyperparametry

hierarchický model:

6

$$Y \rightarrow (\beta, \tau) \rightarrow d_0$$

$$p(Y | \beta, \tau) = \text{verohodnosť } N(X\beta, \tau^{-1} I_n)$$

$$p(\beta, \tau | d_0) = \overset{\text{konjug. systém}}{p(\beta | \tau) p(\tau | d_0)} \sim \text{Gamma}(c_0, d_0)$$

$$\sim N(\beta_0, \tau^{-1} \Sigma_0)$$

$$p(d_0) = ?$$

napí. $p(d_0) \sim \text{Gamma}(g_0, h_0)$

pevné / na'hodné?

6

2. Hierarchicky specifikovaná věrohodnost

[7]

[8]

NTP TER 94073 pokus na myších

[9]

Y_{ij} = hmotnost zárodku j u myši i

$\mu = \mathbb{E}Y_{ij}$ = primární parametěr

obr.

[10-11]

MODEL 1: $Y_{ij} \stackrel{iid}{\sim} \mathcal{N}(\mu, \sigma^2)$

[12]

$\psi \rightarrow$ vhodné?

MODEL 2 (realističtější)?

[13]

$Y_{ij} | b_i \stackrel{nezav.}{\sim} \mathcal{N}(b_i, \sigma^2)$

$\psi \equiv \mu, d^2, \sigma^2$

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

za podmínky ψ :

$$\mathbb{E}Y_{ij} = \mathbb{E}(\mathbb{E}(Y_{ij} | b_i)) = \mathbb{E}(b_i) = \mu$$

Model implikuje (kromě jiného)

[14]

$$\text{cov}(Y_{ij}, Y_{ik}) = \dots = d^2 \quad (\text{SDC})$$

$$\text{var} Y_{ij} = \sigma^2 + d^2$$

$$Y_i = (Y_{i1}, \dots, Y_{im_i})^T \sim \mathcal{N}(\mu \cdot 1, \begin{pmatrix} \sigma^2 + d^2 & & & -d^2 \\ & \ddots & & \\ & & \sigma^2 + d^2 & \\ & & & 1 \\ & & & & \sigma^2 + d^2 \end{pmatrix})$$

compound symmetry

$$f: p(y_i | \psi) \equiv N(\mu, \begin{pmatrix} \sigma^2 + d^2 & d^2 \\ d^2 & \sigma^2 + d^2 \end{pmatrix})$$

↑
tohle jsme
ale nenapsali přímo

Model byl specifikován takto:

$$\begin{aligned} p(y_i | \psi) &= \int p(y_i, b_i | \psi) db_i = \\ &= \int p(y_i | b_i, \psi) \underbrace{p(b_i | \psi)}_{\sim N(\mu, d^2)} db_i \\ &\quad \sim \prod_{j=1}^{m_i} \underbrace{p(y_{ij} | b_i, \psi)}_{\sim N(b_i, \psi)} \end{aligned}$$

$b_i \equiv$ „skrytá“ data

\equiv data vyšší / nižší hierarchické úrovně
- v dalším značena pomocí ξ

OBECNĚ, hierarchicky specifikovaná věrohodnost

$p(y|\psi)$ variace

^{předp.}
^{hierar.}
↓

$$p(y, \xi_1, \dots, \xi_m | \psi) =$$

$$= p(y | \xi_1, \dots, \xi_m, \psi) \cdot p(\xi_1 | \xi_2, \dots, \xi_m, \psi) \dots$$

$$\dots p(\xi_m | \psi)$$

předp. hierarchie

$$= p(y | \xi_1, \psi) p(\xi_1 | \xi_2, \psi) \dots$$


$$\dots p(\xi_{m-1} | \xi_m, \psi) p(\xi_m | \psi)$$

$$p(y|\psi) = \int p(y|\xi_1, \psi) p(\xi_1|\xi_2, \psi) \dots$$

$$\dots p(\xi_{m-1}|\xi_m, \psi) p(\xi_m|\psi)$$

$$d\xi_m d\xi_{m-1} \dots d\xi_2 d\xi_1$$

DATA GENERUJÍCÍ MECHANIZMUS



avšak závisí na
neznaném parametru ψ

$p(y|\psi) =: L(\psi) =$ frekventistická věrohodnost
(se kterou je nutno pracovat při ML atd.)

Pro Bayesovskou inferenci o ψ :

$p(\psi) = \text{apriorní rozdílenní}$ (sabe' hierarchicky
specifikovane' $\ddot{\text{z}}$)
ZAT/11 NE

$$\begin{aligned} p(\psi|\psi) &\propto p(\psi|\psi) p(\psi) \\ &= \int p(\psi|\xi_1, \psi) p(\xi_1|\xi_2, \psi) \dots p(\xi_m|\psi) \\ &\quad d\xi_m \dots d\xi_1 \int p(\psi) \end{aligned}$$

co takle považovat "skrupa" data ξ_1, \dots, ξ_m
na další parametry modelu
o apriorním rozdílenním (opole o ψ):

$$p(\xi_1, \dots, \xi_m, \psi) \stackrel{\text{VEDM}}{=} p(\xi_1|\xi_2, \dots, \xi_m, \psi)$$

$$\cdot p(\xi_2|\xi_3, \dots, \xi_m, \psi) \dots p(\xi_m|\psi) p(\psi)$$

POUŽÍTE TOTÉŽ

CO V HIERAR.

SPECIFIKACI

MODELU PRO VĚROHOD.

$$p(\xi_1|\xi_2, \psi) \cdot p(\xi_2|\xi_3, \psi) \dots p(\xi_m|\psi) p(\psi)$$

POTOM $p(\xi_1, \dots, \xi_m, \psi | \psi) \propto p(\psi | \xi_1, \dots, \xi_m, \psi) \cdot$

$$\cdot p(\xi_1, \dots, \xi_m, \psi) =$$

hierar. model

$$= p(\psi | \xi_1, \psi) p(\xi_1 | \xi_2, \psi) \dots p(\xi_m | \psi) p(\psi)$$

JAK POTOM VYPADA' (marginální)

$$p(\psi|\psi) = \int p(\xi_1, \dots, \xi_m, \psi | \psi) d\xi_m \dots d\xi_1$$

$$= \text{☒}$$

HLE!

řapamatij 2: Y hierarchický specifikovanou věrohodností

$$p(y|\psi) = \int p(y|\xi_1, \psi) p(\xi_1|\xi_2, \psi) \dots p(\xi_{m-1}|\xi_m, \psi) \cdot p(\xi_m|\psi) d\xi_m \dots d\xi_1$$

a sdruženým a priori m rozdělením

$$p(\xi_1, \dots, \xi_m, \psi) = p(\xi_1|\xi_2, \psi) \dots p(\xi_m|\psi) p(\psi)$$

(ježto ξ část odpovídá modelu)

je ~~$p(y|\psi)$~~ má

$p(y|\psi)$ marginálním rozdělením

$$\propto p(\xi_1, \dots, \xi_m, \psi | y)$$

→ zejména pro Monte Carlo (Markov chain) může být (většinou je) výhodně pracovat přímo s

$$p(\xi_1, \dots, \xi_m, \psi | y) \propto$$

$$p(y|\xi_1, \psi) p(\xi_1|\xi_2, \psi) \dots p(\xi_m|\psi) p(\psi)$$

a integrál $p(y|\psi) = \int \boxed{w} d\xi_m \dots d\xi_1$

počítat pouze když to je skutečné
pohyba (při MC málokdy)

→ potřebuji (náhodný) výběr $\propto p(y|\psi)$

\equiv příslušné složitý (náhodného)

výběru $\propto p(\xi_1, \dots, \xi_m, \psi | y)$

Shrnuti (sjednocušené h pouze 1 úroveň strybych dat)

16

DATA: \mathcal{Y}

NEKRYTA DATA: ξ

PARAMETRY (SKUTEČNÉ): ψ

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

$p(\psi)$ = apriorní rozdělání „skutečné“

úspěšně uvažovat jako parametry též ξ s apriorním

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

strukturní („modelová“)
část apriorního model.

$\Theta := (\xi, \psi) \equiv$ parametry pro Bayes. model

$\Rightarrow p(\mathcal{Y}|\psi)$ je marginačním z $p(\xi, \psi|\mathcal{Y})$

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

Těž "skutečné" apriorní rozdělení může
byť specifikačně hierarchicky
(dále opět pouze 1 úroveň)

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

Při počítání je užitečné uvažovat
jako parametry též ξ a apriorním

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

jako
na minulé


$\theta = (\xi, \psi, \xi) =$ parametry pro Bayes model

$\Rightarrow p(\psi|y)$ je marginálním $\neq p(\xi, \psi, \xi|y)$


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

Pozn. Struktura hierarchického modelu

\Leftrightarrow Directed Acyclic Graph (DAG)



Obvykle (ne nutně): Každá hierarchická úroveň



dat má své "skutečné" parametry
a ty mají své hyperparametry

$$\Theta = \left(\underbrace{\xi_{\bar{1}}}_{\text{skytá data}}, \underbrace{\psi_0, \psi_1}_{\text{"skutečné" parametry}}, \underbrace{\xi_0, \xi_1}_{\text{hyperparametry}} \right)$$

→ MODEL (věrohodnost pro Bayes model)

$$p(y|\theta) = p(y|\xi_{\bar{1}}, \psi_0)$$

APRIORNI pro θ

$$p(\theta) = p(\xi_{\bar{1}}, \psi_0, \psi_1, \xi_0, \xi_1) =$$

$$= p(\xi_{\bar{1}}|\psi_1) \cdot p(\psi_1|\xi_1) p(\xi_1)$$

$$\cdot p(\psi_0|\xi_0) p(\xi_0)$$

(= část "model", část apriorního model)

Frekventistická věrohodnost ($\psi = (\psi_0, \psi_1)$)

$$L_F(\psi) = p(y|\psi) = \int p(y, \xi_{\bar{1}}|\psi) d\xi_{\bar{1}} =$$

$$= \int p(y|\xi_{\bar{1}}, \psi) p(\xi_{\bar{1}}|\psi) d\xi_{\bar{1}} =$$

hierarchie

v DAG


$$\int p(y|\xi_{\bar{1}}, \psi_0) p(\xi_{\bar{1}}|\psi_1) d\xi_{\bar{1}}$$

POSTERIORNI PRO θ :

$$p(\theta|y) \propto \text{POUČIN ŽE PÍPER Z DAG} = p(y|\xi_{\bar{1}}, \psi_0) p(\xi_{\bar{1}}|\psi_1) p(\psi_1|\xi_1) \cdot p(\xi_1) \cdot p(\psi_0|\xi_0) p(\xi_0)$$

TOP: Jak data generující mechanismus, tak apriorní rozdelení mohou být specifikovány hierarchicky s více než jednou úrovní.

Typicky: Každá úroveň má své parametry (ne nutně):



$$\Theta = (\xi_{11}, \xi_{21}, \xi_{31}, \dots, \psi_0, \psi_1, \psi_2, \psi_3, \dots, \xi_0^{(1)}, \dots)$$

= parametry pro Bayes. model

aposteriorní pro Θ :

$p(\Theta | y)$ a součin řádek z DAG

$$= p(y | \xi_{11}, \psi_0) p(\xi_{11} | \psi_1) p(\xi_{11} | \psi_1) p(\xi_{21} | \psi_2) p(\xi_{21} | \psi_2) p(\xi_{31} | \psi_3) \dots$$

MODEL (MECHANIZMUS PRO DATA)

APRIORNÍ (HIERARCH.)

$$\left[\begin{array}{l} p(\psi_0 | \xi_0^{(1)}) p(\xi_0^{(1)} | \xi_0^{(2)}) \dots \\ \vdots \\ p(\psi_3 | \xi_3^{(1)}) p(\xi_3^{(1)} | \xi_3^{(2)}) \dots \end{array} \right]$$

"ANOVA" hierarchický model

$$Y_{ij} | b_i \sim N(b_i, \sigma^2)$$

$$b_i \sim N(\mu, d^2)$$

$$Y = (Y_1, \dots, Y_N)$$


$$Y_i = (Y_{i1}, \dots, Y_{im_i})$$

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

$$\psi = (\tau, \mu, q)$$

$$\tau = \sigma^{-2}$$

$$q = d^{-2}$$



$$\Theta = (\underbrace{b_1, \dots, b_N}_{\xi}, \underbrace{\tau, \mu, q}_{\psi})$$

$$p(\Theta | Y) \propto \prod_{i=1}^N p(Y_i | b_i, \tau) p(b_i | \mu, q) p(\mu, q) p(\tau)$$

data modelu $\quad = p(\mu, q, \tau)$

$N(\dots)$

$$p(\mu, q, \tau) = p(\mu, q) p(\tau)$$

↑
předpokládáme

napiš konjugované rozdělení

$$p(\mu, q) = p(\mu | q) p(q) \sim \text{Ga}(a_0, b_0)$$

$$\sim N(\mu_0, k_0^{-1} q^{-1})$$

$$p(\tau) \sim \text{Ga}(c_0, d_0)$$

hyperparametry: $\mu_0, k_0, a_0, b_0, c_0, d_0$

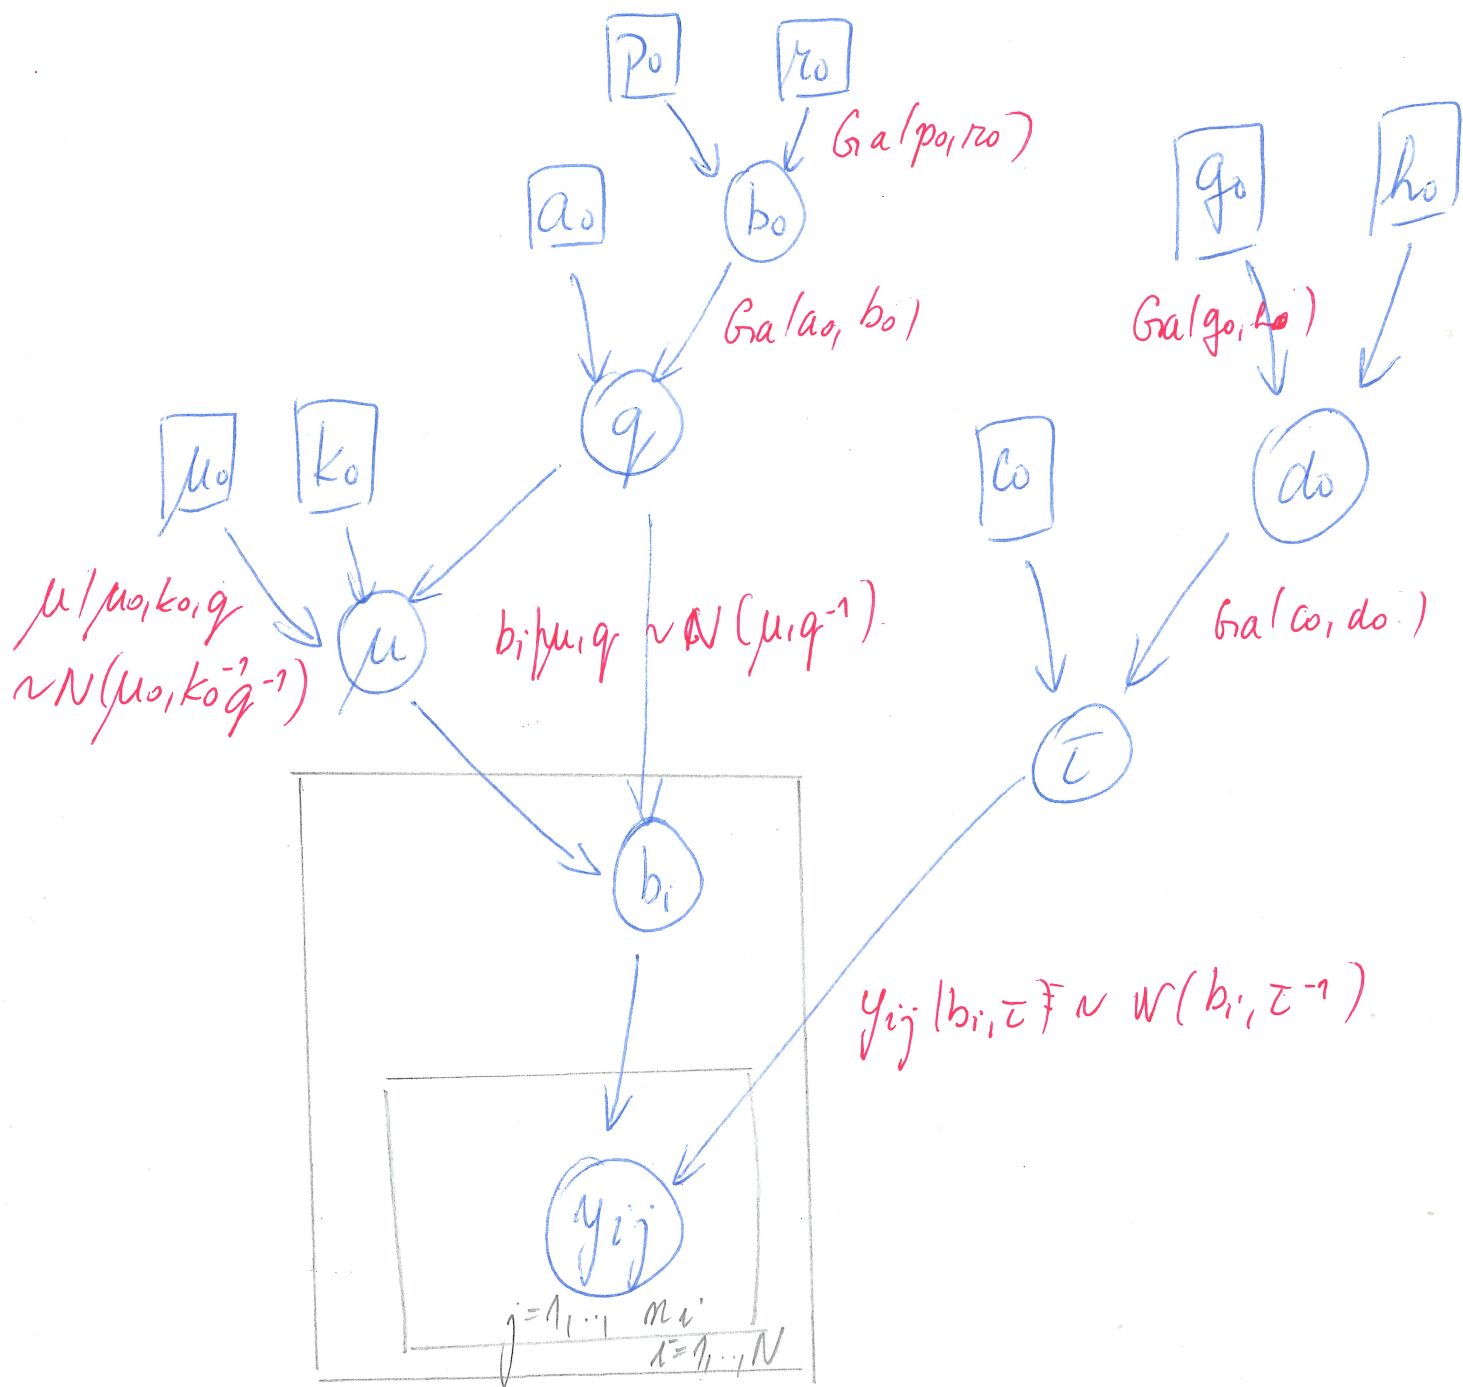
necht' na'hodne'

$$\xi = (b_0, d_0)$$

$$p(\xi) = p(b_0) \cdot p(d_0)$$

↑
předp. nezáv.

DAG včetně pevných hyperparametrů



např. $p(b_0) \sim \text{Gra}(p_0, r_0)$
 $p(d_0) \sim \text{Gra}(g_0, h_0)$

$$\Theta = (\underbrace{b_1, \dots, b_N}_{\xi}, \underbrace{\tau, \mu, q}_{\psi}, \underbrace{b_0, d_0}_{\xi})$$

$p(\Theta | y) \propto$ součin
 příšek
 z DAG

Jak volit peone' hyperparametry?

20

→ potreba chapat rujanam jednosluzide
parametru

21-22