

# Teoria de Resposta ao Item

## Métodos de estimação: bayesianos e marginal-perfilados bayesianos

Caio L. N. Azevedo, IMECC/Unicamp

## Inferência bayesiana

- ▶ Sejam  $A$  e  $B_1, B_2, \dots$  eventos associados à um mesmo espaço de probabilidade  $(\Omega, \mathcal{A}, \mathcal{P})$
- ▶ Pelo teorema da probabilidade total, temos que
$$P(A) = \sum_{i=1}^{\infty} P(A|B_i)P(B_i)$$
- ▶ Pelo teorema de Bayes, temos que

$$P(B_i|A) = \frac{P(A \cap B_i)}{P(A)} = \frac{P(A|B_i)P(B_i)}{\sum_{i=1}^{\infty} P(A|B_i)P(B_i)}$$

## Inferência bayesiana

- ▶ Seja  $\mathbf{X}$  um vetor aleatório com densidade  $p(\mathbf{x}|\beta)$  (verossimilhança) em que  $\beta$  é um vetor de parâmetros (deconhecidos),  $\beta \in \mathcal{R}^p$ .
- ▶ Admita que a ingnorância a respeito de  $\beta$  pode ser traduzida por uma densidade  $p(\beta|\eta_\beta) \equiv p(\beta)$ . As componentes de  $\eta_\beta$  são conhecidas como hiperparâmetros.
- ▶ A inferência bayesiana baseia-se na utilização da distribuição a posteriori de  $\beta$ , ou seja:

$$\begin{aligned} p(\beta|\mathbf{x}) &= \frac{p(\mathbf{x}, \beta)}{p(\mathbf{x})} = \frac{p(\mathbf{x}|\beta)p(\beta)}{\int p(\mathbf{x}|\beta)p(\beta)d\beta} \\ &\propto p(\mathbf{x}|\beta)p(\beta) \end{aligned}$$

- ▶ As estimativas de MV não estão definidas para escores nulos ou perfeitos.
- ▶ Escore nulo  $L(\theta_j) = \prod_{i=1}^I (1 - P_{ij})$
- ▶ Escore perfeito  $L(\theta_j) = \prod_{i=1}^I (P_{ij})$
- ▶ Solução: utilização de métodos bayesianos.

## Parâmetros dos itens conhecidos

$$\begin{aligned} p(\boldsymbol{\theta}|\mathbf{y}, \zeta) &= \frac{p(\mathbf{y}|\boldsymbol{\theta}, \zeta)p(\boldsymbol{\theta})}{\int p(\mathbf{y}|\boldsymbol{\theta}, \zeta)p(\boldsymbol{\theta})d\boldsymbol{\theta}} \propto p(\mathbf{y}|\boldsymbol{\theta}, \zeta)p(\boldsymbol{\theta}) \\ &= \left( \prod_{i=1}^I \prod_{j=1}^n P_{ij}^{y_{ij}} Q_{ij}^{1-y_{ij}} \right) \left( \prod_{j=1}^n p(\theta_j) \right) \\ &= \prod_j^n (p(\mathbf{y}_{\cdot j}|\theta_j, \zeta)p(\theta_j)) = \prod_{j=1}^n p(\theta_j|\mathbf{y}_{\cdot j}, \zeta_i) \end{aligned}$$

## Moda a posteriori

- ▶ Maximizar  $\ln p(\boldsymbol{\theta}|\mathbf{y}, \zeta) = \sum_{j=1}^n \ln p(\theta_j|\mathbf{y}_j, \zeta)$

$$S(\theta_j)_B = \frac{\partial l_j^*(\theta_j)}{\partial \theta_j} = \frac{\partial l(\theta_j)}{\partial \theta_j} + \frac{\partial \ln g(\theta_j|\boldsymbol{\eta})}{\partial \theta_j}.$$

$$S(\theta_j)_B = \sum_{i=1}^I (y_{ij} - P_{ij}) - \frac{\theta_j - \mu_\theta}{\sigma_\theta^2}.$$

- ▶ Informação de Fisher

$$I(\theta_j) = \sum_{i=1}^I P_{ij} Q_{ij} + \frac{1}{\sigma_\theta^2}$$

- ▶ Erro-padrão a posteriori (assintótico)

$$\mathcal{EP}(\theta_j) = \sqrt{I(\hat{\theta}_j)^{-1}}$$

## Média a posteriori

$$E [\theta_j | \mathbf{y}_j, \zeta, \eta] = \frac{\int_{\mathfrak{R}} \theta p(\mathbf{y}_j | \theta_j, \zeta) p(\theta_j) d\theta}{\int_{\mathfrak{R}} p(\mathbf{y}_j | \theta_j, \zeta) p(\theta_j) d\theta}.$$

$$\begin{aligned} E [\theta_j | \mathbf{y}_j, \zeta, \eta] &\approx E [\bar{\theta}_j | \mathbf{y}_j, \zeta, \eta] = \frac{\sum_{l=1}^q \bar{\theta}_l P(\mathbf{Y}_j | \bar{\theta}_l, \zeta) g(\bar{\theta}_l | \eta)}{\sum_{l=1}^q P(\mathbf{Y}_j | \bar{\theta}_l, \zeta) g(\bar{\theta}_l | \eta)} \\ &= \frac{\sum_{l=1}^q \bar{\theta}_l P(\mathbf{Y}_j | \bar{\theta}_l, \zeta) A_l}{\sum_{l=1}^q P(\mathbf{Y}_j | \bar{\theta}_l, \zeta) A_l}. \end{aligned}$$

## Variância a posteriori

$$\text{Var} [\theta_j | \mathbf{y}_j, \zeta, \eta] = \frac{\int_{\mathfrak{R}} [\theta - \mathbf{E}(\theta)]^2 P(\mathbf{Y}_j | \theta, \zeta) g(\theta | \eta) d\theta}{\int_{\mathfrak{R}} P(\mathbf{Y}_j | \theta, \zeta) g(\theta | \eta) d\theta}$$

Em termos dos pontos de quadratura, temos que

$$\text{Var} [\bar{\theta}_j | \mathbf{y}_j, \zeta, \eta] = \frac{\sum_{l=1}^q \{\bar{\theta}_l - \mathbf{E}[\bar{\theta}_j | \mathbf{y}_j, \zeta, \eta]\}^2 P(\mathbf{Y}_j | \bar{\theta}_l, \zeta) g(\bar{\theta}_l | \eta)}{\sum_{l=1}^q P(\mathbf{Y}_j | \bar{\theta}_l, \zeta) g(\bar{\theta}_l | \eta)}$$

Erro-padrão a posteriori

$$\mathcal{EP}[\bar{\theta}_j | \mathbf{y}_j, \zeta, \eta] = \sqrt{\text{Var} [\bar{\theta}_j | \mathbf{y}_j, \zeta, \eta]}$$



- Máxima Verossimilhança - MV :

- ⊕ Para testes “longos” produz estimadores não viciados;
- ⊖ Não está definido para alguns padrões de resposta.

- Bayesiano - EAP :

- ⊕ Definido para qualquer padrão de resposta;
- ⊕ Possui o menor erro médio;
- ⊕ Sua implementação é relativamente simples;
- ⊖ Viciado;
- ⊖ Necessidade de uma distribuição a priori para  $\theta$ .

- Bayesiano - MAP :

- ⊕ Definido para qualquer padrão de resposta;
- ⊖ Viciado.
- ⊖ Exige cálculos mais complexos do que o método de MV;
- ⊖ Necessidade de uma distribuição a priori para  $\theta$ .

## Traços latentes conhecidos

$$\begin{aligned} p(\mathbf{b}|\mathbf{y}, \zeta) &= \frac{p(\mathbf{y}|\boldsymbol{\theta}, \zeta)p(\mathbf{b})}{\int p(\mathbf{y}|\boldsymbol{\theta}, \zeta)p(\mathbf{b})d\mathbf{b}} \propto p(\mathbf{y}|\boldsymbol{\theta}, \zeta)p(\mathbf{b}) \\ &= \left( \prod_{i=1}^I \prod_{j=1}^n P_{ij}^{y_{ij}} Q_{ij}^{1-y_{ij}} \right) \left( \prod_{i=1}^n p(b_i) \right) \\ &= \prod_i (p(\mathbf{y}_{i.}|\theta_j, \zeta)p(b_i)) = \prod_{i=1}^I p(b_i|\mathbf{y}_{i.}, \boldsymbol{\theta}) \end{aligned}$$

- ▶ Que priori utilizar para os parâmetros de dificuldade?
- ▶  $b_i \sim N(\mu_b, \sigma_b^2)$  (dificuldades são “habilidades”).

## Traços latentes conhecidos

$$\begin{aligned} p(\mathbf{b}|\mathbf{y}, \zeta) &= \frac{p(\mathbf{y}|\boldsymbol{\theta}, \zeta)p(\mathbf{b})}{\int p(\mathbf{y}|\boldsymbol{\theta}, \zeta)p(\mathbf{b})d\mathbf{b}} \propto p(\mathbf{y}|\boldsymbol{\theta}, \zeta)p(\mathbf{b}) \\ &= \left( \prod_{i=1}^I \prod_{j=1}^n P_{ij}^{y_{ij}} Q_{ij}^{1-y_{ij}} \right) \left( \prod_{i=1}^n p(b_i) \right) \\ &= \prod_i (p(\mathbf{y}_i|\theta_j, \zeta)p(b_i)) = \prod_{i=1}^I p(b_i|\mathbf{y}_i, \boldsymbol{\theta}) \end{aligned}$$

- ▶ Que priori utilizar para os parâmetros de dificuldade?
- ▶  $b_i \sim N(\mu_b, \sigma_b^2)$  (dificuldades são “habilidades”).

## Moda a posteriori

- ▶ Maximizar  $\ln p(\mathbf{b}|\mathbf{y}, \boldsymbol{\theta}) = \sum_{i=1}^I \ln p(b_i|\mathbf{y}_{\cdot j}, \boldsymbol{\theta})$

$$S(b_i)_B = \frac{\partial l_j^*(b_i)}{\partial b_i} = \frac{\partial l(b_i)}{\partial b_i} + \frac{\partial \ln g(b_i)}{\partial b_i}.$$

$$S(b_i)_B = \sum_{j=1}^n (y_{ij} - P_{ij}) - \frac{b_i - \mu_b}{\sigma_b^2}.$$

- ▶ Informação de Fisher

$$I(b_i) = \sum_{j=1}^n P_{ij} Q_{ij} + \frac{1}{\sigma_b^2}$$

- ▶ Erro-padrão a posteriori (assintótico)

$$\mathcal{EP}(b_i) = \sqrt{I(\hat{b}_i)^{-1}}$$

## Posteriori

$$p(\zeta, \eta | \mathbf{y}_{..}) \propto \left\{ \prod_{j=1}^n \int_{\mathfrak{R}} \prod_{i=1}^I P(\mathbf{Y}_{ij} | \theta, \zeta_i) g(\theta, \eta) d\theta \right\} \left\{ \prod_{i=1}^I p(\zeta_i | \tau_i) \right\}$$

## Log-posteriori

$$\ln p(\zeta, \eta | \mathbf{y}_{..}) \propto \left\{ \sum_{j=1}^n \ln \int_{\mathfrak{R}} \prod_{i=1}^I P(\mathbf{Y}_{ij} | \theta, \zeta_i) g(\theta, \eta) d\theta \right\} + \left\{ \sum_{i=1}^I \ln p(\zeta_i | \tau_i) \right\}$$

## Maximizar a log-posteriori

$$\frac{\partial}{\partial \zeta_i} \ln p(\zeta, \eta | \mathbf{y}_{..}) \propto \left\{ \sum_{j=1}^n \frac{\partial}{\partial \zeta_i} \ln \int_{\mathfrak{R}} \prod_{i=1}^I P(\mathbf{Y}_{ij} | \theta, \zeta_i) g(\theta, \eta) d\theta \right\} + \left\{ \frac{\partial}{\partial \zeta_i} \ln p(\zeta_i | \tau_i) \right\}$$

## Expressões

$$\begin{aligned}
 S(b_i)_{BM} &= \sum_{l=1}^q \left[ \left( \sum_{j=1}^n y_{ij} g_j^* (\bar{\theta}_l) - P_{il} \sum_{j=1}^n g_j^* (\bar{\theta}_l) \right) \right] - \frac{b_i - \mu_b}{\sigma_b^2} \\
 &= \sum_{l=1}^q [(\bar{r}_{il} - \bar{f}_{il} P_{il})] - \frac{b_i - \mu_b}{\sigma_b^2}, \\
 I(b_i)_{BM} &= \sum_{l=1}^q \bar{f}_{il} P_{il} Q_{il} + \frac{1}{\sigma_b^2}
 \end{aligned}$$

## Algoritmo EM - distribuição a posteriori

- ▶ Tomando a esperança da log-posteriori, condicionada a  $(\mathbf{Y}'_{..}, \mathbf{b}')'$ , para os dados completos, temos que

$$E[\ln p(\mathbf{b} | (\mathbf{Y}'_{..}, \mathbf{b}')')] = \bar{C} + \sum_{i=1}^I \sum_{l=1}^q \{ \bar{r}_{il} \ln P_{il} + (\bar{f}_{il} - \bar{r}_{il}) \ln Q_{il} \} + \ln p(\mathbf{b}),$$

em que

$$\bar{r}_{il} = E[r_{il} | \mathbf{Y}_{..}, \mathbf{b}], \quad \bar{f}_{il} = E[f_{il} | \mathbf{Y}_{..}, \mathbf{b}] \quad \text{e} \quad \bar{C} = E[C | \mathbf{Y}_{..}, \mathbf{b}].$$

- ▶ Dessa forma, os passos E e M são :

- ▶ **Passo E**

Usar os pontos de quadratura  $\bar{\theta}_l$ , os pesos  $A_l$ ,  $l = 1, \dots, q$  e estimativas iniciais dos parâmetros dos itens,  $\hat{\mathbf{b}}_i$ ,  $i = 1, \dots, I$ , para gerar  $g_j^*(\bar{\theta}_l)$  e, posteriormente,  $\bar{r}_{il}$  e  $\bar{f}_{il}$ ,  $i = 1, \dots, I$  e  $l = 1, \dots, q$ .

- ▶ **Passo M**

Com  $\mathbf{r}$  e  $\mathbf{f}$  obtidos no Passo E, resolver as equações de estimação para  $\zeta_i$ ,  $i = 1, \dots, I$ , usando o algoritmo de Newton-Raphson ou Escore de Fisher.

## Passo M

## ▶ Passo M

$$\hat{b}_i^{(t+1)} = \hat{b}_i^{(t)} + I(\hat{b}_i^{(t)})^{-1} S(\hat{b}_i^{(t)})$$

em que

$$\begin{aligned} S(b_i) &= \sum_{l=1}^q \left[ \left( \sum_{j=1}^n y_{ij} g_j^* (\bar{\theta}_l) - P_{il} \sum_{j=1}^n g_j^* (\bar{\theta}_l) \right) \right] - \frac{b_i - \mu_b}{\sigma_b^2} \\ &= \sum_{l=1}^q [(\bar{r}_{il} - \bar{f}_{il} P_{il})] , \\ I(b_i) &= \sum_{l=1}^q \bar{f}_{il} P_{il} Q_{il} + \frac{1}{\sigma_b^2} \end{aligned}$$



## Máxima Verossimilhança Marginal - MVM:

- ⊕ Possui propriedades assintóticas: as estimativas dos parâmetros  $a_i$ ,  $b_i$  e  $c_i$  são consistentes;
- ⊕ Uma vez estimados os parâmetros dos itens, pode-se estimar as habilidades através de métodos simples;
- ⊕ Permite resolver o problema de indeterminação (métrica) relativo ao modelo, uma vez que se atribui um parâmetro de escala e de posição para a distribuição das habilidades;
- ⊕ Permite caracterizar empiricamente a distribuição das habilidades;
- ⊖ Não está definido para itens com acerto total ou erro total;
- ⊖ É bastante trabalhoso computacionalmente;
- ⊖ Necessidade do estabelecimento de uma distribuição para  $\theta$ ;
- ⊖ Apresenta problemas na estimação do parâmetro  $c_i$  em alguns casos; deve ser usado somente com um número suficientemente grande de respondentes.

### Moda marginal a Posteriori - MMAP:

- ⊕ Definido para qualquer padrão de resposta;
- ⊕ Uma vez estimados os parâmetros dos itens, pode-se estimar as habilidades através de métodos simples;
- ⊕ Permite resolver o problema de indeterminação (métrica) relativo ao modelo, uma vez que se atribui um parâmetro de escala e de posição para a distribuição das habilidades;
- ⊕ Permite caracterizar empiricamente a distribuição das habilidades;
- ⊖ É mais trabalhoso computacionalmente do que o MVM;
- ⊖ Necessidade de distribuições a priori para os parâmetros dos itens.

## Posteriori

$$p(\zeta, \eta | \mathbf{y}_{..}) \propto \left\{ \prod_{j=1}^n \int_{\mathfrak{R}} \prod_{i=1}^I P(\mathbf{Y}_{ij} | \theta, \zeta_i) g(\theta, \eta) d\theta \right\} \left\{ \prod_{i=1}^I p(\zeta_i | \tau_i) \right\} \left\{ \prod_{i=1}^I p(\tau_i) \right\}$$

## Log-posteriori

$$\begin{aligned} \ln p(\zeta, \eta | \mathbf{y}_{..}) &\propto \left\{ \sum_{j=1}^n \ln \int_{\mathfrak{R}} \prod_{i=1}^I P(\mathbf{Y}_{ij} | \theta, \zeta_i) g(\theta, \eta) d\theta \right\} + \left\{ \sum_{i=1}^I \ln p(\zeta_i | \tau_i) \right\} \\ &\quad + \left\{ \sum_{i=1}^I \ln p(\tau_i) \right\} \end{aligned}$$

## Maximizar a log-posteriori

$$\frac{\partial}{\partial \zeta_i} \ln p(\zeta, \eta | \mathbf{y}_{..}) \propto \left\{ \sum_{j=1}^n \frac{\partial}{\partial \zeta_i} \ln \int_{\mathfrak{R}} \prod_{i=1}^I P(\mathbf{Y}_{ij} | \theta, \zeta_i) g(\theta, \eta) d\theta \right\} + \left\{ \frac{\partial}{\partial \zeta_i} \ln p(\zeta_i | \tau_i) \right\}$$

Parâmetro a

$$p(a_i | \mu_{a_i}, \sigma_{a_i}^2) = \frac{1}{\sqrt{2\pi} a_i \sigma_{a_i}} \exp \left[ -\frac{1}{2\sigma_{a_i}^2} (\ln a_i - \mu_{a_i})^2 \right].$$

Parâmetro b

$$p(b_i | \mu_{b_i}, \sigma_{b_i}^2) = \frac{1}{\sqrt{2\pi} \sigma_{b_i}} \exp \left\{ -\frac{(b_i - \mu_{b_i})^2}{2\sigma_{b_i}^2} \right\}$$

Parâmetro c

$$p(c_i | \alpha_i, \beta_i) = \frac{\Gamma(\alpha_i + \beta_i - 2)}{\Gamma(\alpha_i - 1)\Gamma(\beta_i - 1)} c_i^{\alpha_i - 2} (1 - c_i)^{\beta_i - 2}.$$

$$\mathbf{S}(\zeta_i)_B = \sum_{l=1}^q (\bar{r}_{il} - f_{il}P_{il}) \mathbf{h}_{il} + \boldsymbol{\lambda}_i,$$

com

$$\mathbf{h}_{ij} = \left( P_{ij}^* Q_{ij}^* \right)^{-1} \left( \frac{\partial P_{ij}}{\partial \zeta_i} \right) = \begin{pmatrix} D(1-c_i)(\theta_j - b_i) \\ -Da_i(1-c_i) \\ \frac{1}{P_{ij}^*} \end{pmatrix}$$

$$\boldsymbol{\lambda}_i = \left[ \frac{1}{a_i} \left[ 1 + \frac{\ln a_i - \mu_{a_i}}{\sigma_{a_i}^2} \right]; -\frac{(b_i - \mu_{b_i})}{\sigma_{b_i}^2}; \frac{\alpha_i - 2}{c_i} - \frac{\beta_i - 2}{1 - c_i} \right]'$$

$$\frac{\partial^2}{\partial \zeta_i \partial \zeta_i'} \ln p(\zeta, \eta | \mathbf{y} \dots) \propto \left\{ \sum_{j=1}^n \frac{\partial^2}{\partial \zeta_i \partial \zeta_i'} \ln \int_{\mathfrak{R}} \prod_{i=1}^I P(\mathbf{Y}_{ij} | \theta, \zeta_i) g(\theta, \eta) d\theta \right\}$$

$$\left\{ \frac{\partial^2}{\partial \zeta_i \partial \zeta_i'} \ln p(\zeta_i | \tau_i) \right\}$$

$$\mathbf{I}(\zeta_i)_{BM} = \sum_{l=1}^q \bar{f}_{il} P_{il}^* Q_{il}^* \mathbf{h}_{il} \mathbf{h}_{il}' - \mathbf{\Lambda}_i.$$







$$\mathbf{\Lambda}_i = \begin{bmatrix} \frac{[\sigma_{a_i}^2 + \ln a_i - \mu_{a_i} - 1]}{\mu_{a_i}^2 \sigma_{a_i}^2} & \cdot & \cdot & \cdot \\ 0 & -\frac{1}{\sigma_{b_i}^2} & \cdot & \cdot \\ 0 & 0 & -\left[ \frac{\alpha_i - 2}{c_i^2} \right] + \frac{\beta_i - 2}{(1 - c_i)^2} & \cdot \end{bmatrix}.$$




- ▶ Foram gerados  $n = 5000$  valores independentes de uma distribuição  $N(0,1)$  a fim de servirem como as habilidades dos indivíduos.
- ▶  $I = 50$  itens de maneira a cobrir os valores apropriados para os parâmetros:  $a$  variando de 1,0 a 1,8,  $b$  variando de -2,0 a 2,0 e  $c = 0,20$  e 0,25.
- ▶ Para a geração das respostas foi construído um programa em linguagem Ox.
- ▶ Para a obtenção das estimativas dos parâmetros (itens e habilidades) foi usado o programa Bilog

**Tabela:** Estatísticas relativas as estimativas dos parâmetros dos itens

Estatística	Parâmetro					
	discriminação(a)		dificuldade(b)		acerto casual (c)	
	MVM	BM	MVM	BM	MVM	BM
<b>SQR</b>	1,74	1,30	1,81	0,65	0,31	0,07
<b>SVar</b>	1,27	0,92	3,10	0,89	0,75	0,14
<b>SEQM</b>	3,01	2,22	4,91	1,54	1,06	0,21







## Moda a posteriori

## Log-posteriori

$$\ln g_j^*(\theta_j) = \text{Const} + \ln P(\mathbf{Y}_{\cdot j}|\theta_j, \zeta) + \ln g(\theta_j|\boldsymbol{\eta}). \quad (1)$$

Equação de estimação bayesiana

$$\frac{\partial \ln g_j^*(\theta_j)}{\partial \theta_j} = \frac{\partial \ln P(\mathbf{Y}_{\cdot j}|\theta_j, \zeta)}{\partial \theta_j} + \frac{\partial \ln g(\theta_j|\boldsymbol{\eta})}{\partial \theta_j} = 0.$$

Informação de Fisher

$$I(\theta_j) = \sum_{i=1}^I P_{ij}^* Q_{ij}^* W_{ij} h_{ij}^2 - \frac{1}{\sigma^2}. \quad (2)$$

Scoring de Fisher

$$\hat{\theta}_j^{(t+1)} = \hat{\theta}_j^{(t)} + I(\theta_j^{(t)})^{-1} S(\theta_j^{(t)})$$

$$g(\theta|\mathbf{y}_{.j}, \zeta, \boldsymbol{\eta}) = \frac{P(\mathbf{y}_{.j}|\theta, \zeta)g(\theta|\boldsymbol{\eta})}{P(\mathbf{y}_{.j}|\zeta, \boldsymbol{\eta})}. \quad (3)$$

Segue que a esperança da posteriori é

$$\hat{\theta}_j \equiv E[\theta|\mathbf{y}_{.j}, \zeta, \boldsymbol{\eta}] = \frac{\int_{\mathfrak{R}} \theta g(\theta|\boldsymbol{\eta})P(\mathbf{y}_{.j}|\theta, \zeta)d\theta}{\int_{\mathfrak{R}} g(\theta|\boldsymbol{\eta})P(\mathbf{y}_{.j}|\theta, \zeta)d\theta}.$$

$$\begin{aligned} E[\theta_j|\mathbf{y}_{.j}, \zeta, \boldsymbol{\eta}] &\approx E[\bar{\theta}_j|\mathbf{y}_{.j}, \zeta, \boldsymbol{\eta}] = \frac{\sum_{l=1}^q \bar{\theta}_l P(\mathbf{Y}_{.j}|\bar{\theta}_l, \zeta)g(\bar{\theta}_l|\boldsymbol{\eta})}{\sum_{l=1}^q P(\mathbf{Y}_{.j}|\bar{\theta}_l, \zeta)g(\bar{\theta}_l|\boldsymbol{\eta})} \\ &= \frac{\sum_{l=1}^q \bar{\theta}_l P(\mathbf{Y}_{.j}|\bar{\theta}_l, \zeta)A_l}{\sum_{l=1}^q P(\mathbf{Y}_{.j}|\bar{\theta}_l, \zeta)A_l}. \end{aligned}$$

E a variância a posteriori

$$\text{Var}(\theta_j) \equiv \text{Var}[\theta | \mathbf{y}_{.j}, \zeta, \eta] = \frac{\int_{\mathfrak{R}} (\theta - E(\theta))^2 g(\theta | \eta) P(\mathbf{y}_{.j} | \theta, \zeta) d\theta}{\int_{\mathfrak{R}} g(\theta | \eta) P(\mathbf{y}_{.j} | \theta, \zeta) d\theta}.$$

$$\text{Var}[\bar{\theta}_j | \mathbf{y}_{.j}, \zeta, \eta] = \frac{\sum_{l=1}^q \left\{ \bar{\theta}_l - E[\bar{\theta}_j | \mathbf{y}_{.j}, \zeta, \eta] \right\}^2 P(\mathbf{Y}_{.j} | \bar{\theta}_l, \zeta) g(\bar{\theta}_l | \eta)}{\sum_{l=1}^q P(\mathbf{Y}_{.j} | \bar{\theta}_l, \zeta) g(\bar{\theta}_l | \eta)}$$

## Esperança a posteriori

- ▶ MV com MVM : estimativa de máxima verossimilhança das habilidades usando a estimativa de máxima verossimilhança marginal dos parâmetros dos itens.
- ▶ MV com MMAP : estimativa de máxima verossimilhança das habilidades usando a estimativa bayesiana marginal dos parâmetros dos itens.
- ▶ EAP com MVM : estimativa da esperança a posteriori das habilidades usando a estimativa de máxima verossimilhança marginal dos parâmetros dos itens.
- ▶ EAP com MMAP : estimativa da esperança a posteriori das habilidades usando a estimativa de bayesiana marginal dos parâmetros dos itens.
- ▶ MAP com MVM : estimativa da moda a posteriori das habilidades usando a estimativa de máxima verossimilhança marginal dos parâmetros dos itens.
- ▶ MAP com MMAP : estimativa da moda a posteriori das habilidades usando a estimativa bayesiana marginal dos parâmetros dos itens.

Tabela: Estatísticas relativas as estimativas das habilidades

Métodos de Estimação	Estatísticas		
	SQR	SQVar	SQM
<b>MV com MVM</b>	831,08	30938766,88	30939597,96
<b>MV com MMAP</b>	807,59	22954776,39	22955583,98
<b>EAP com MVM</b>	626,85	632,70	1259,55
<b>EAP com MMAP</b>	624,10	638,09	1262,20
<b>MAP com MVM</b>	628,80	617,02	1245,82
<b>MAP com MMAP</b>	625,44	623,37	1248,81

Esperança a posteriori

