

# Métodos de estimação: moda marginal a posteriori/marginal-perfilados bayesianos

Prof. Caio Azevedo

# Histórico da estimação na TRI

- Características.
  - Número elevados de parâmetros para estimar.
  - A verificação das propriedades dos estimadores é muito complicada.
  - Falta de identificabilidade.
  - Necessidade de utilização de métodos numéricos.
  - Espaços paramétricos restritos.

# Histórico da estimação na TRI

- Máxima Verossimilhança Marginal, MVM, (Bock and Lieberman, 1970).
- MVM via pseudo algoritmo EM (Bock and Aitkin, 1981).
- Moda marginal a posteriori via pseudo algoritmo EM (Mislevy, 1986).
- MCMC via dados aumentados (Albert, 1992).
- MCMC via algoritmo de MH (Patz and Junker, 1999).
- Algoritmo EM via expansão paramétrica (Rubin and Thomas, 2000).
- Algoritmo EM estocástico (SEM), (Fox, 2000).
- Algoritmo Robbins-Monro de Metropolis-Hastings (MHRM), Cai (2010).
- Algoritmo CADEM (conditional augmented data EM) (Azevedo and Andrade (2013)).

# Modelo logístico unidimensional de 3 parâmetros

$$P(Y_{ij} = 1 | (\theta_j, \zeta_i)) = c_i + (1 - c_i) \frac{1}{1 + e^{-Da_i(\theta_j - b_i)}}$$

$i = 1, \dots, I$  (item),  $j = 1, \dots, n$  (individuo),

- $Y_{ij}$  : é a resposta do indivíduo  $j$  ao item  $i$ . É igual a 1 se o indivíduo responde corretamente e 0 caso contrário.
- $\theta_j$  : é o traço latente (conhecimento, nível de depressão, etc) do indivíduo  $j$ .
- $\zeta_i$  :  $(a_i, b_i, c_i)$ .
- $a_i$  : é o parâmetro de discriminação associado ao item  $i$ .
- $b_i$  : é o parâmetro de dificuldade associado ao item  $i$ .
- $c_i$  : é o parâmetro de “acerto casual” associado ao item  $i$ .

- Seja  $\theta$  um parâmetro associado a um determinado modelo  $p(\mathbf{x}|\theta)$  verossimilhança para o qual assumimos uma priori  $p(\theta)$ .
- Posteriori: 
$$p(\theta|\mathbf{x}) = \frac{p(\mathbf{x}|\theta)p(\theta)}{\int_{\Theta} p(\mathbf{x}|\theta)p(\theta)d\theta}$$
- Problema (na TRI): é muito complicado obter as posteriores marginais de interesse, de forma analítica. Se  $\theta = (\theta_1, \theta_2)'$  elas seriam dadas por  $p(\theta_1|\mathbf{x})$  e  $p(\theta_2|\mathbf{x})$ .
- Uma solução maximizar a posteriori (marginal) dos parâmetros dos itens.

# Estimação por Máxima Verossimilhança

- Maximizar a verossimilhança:

$$L(\theta, \zeta) = \prod_{i=1}^I \prod_{j=1}^n P_{ij}^{y_{ij}} Q_{ij}^{1-y_{ij}}$$

- Não identificabilidade

$$\begin{aligned} P_{ij} &= c_i + \frac{1 - c_i}{1 + e^{-D a_i (\theta_j - b_i)}} = c_i + \frac{1 - c_i}{1 + e^{-D \frac{a_i}{\alpha} \left( \frac{(\theta_j - \beta)}{\alpha} - \frac{(b_i - \beta)}{\alpha} \right)}} \\ &= c_i + \frac{1 - c_i}{1 + e^{-D a_i^* (\theta_j^* - b_i^*)}} \end{aligned}$$

- Estimação simultânea.

- Inversão de matrizes da ordem de  $n \times I$ .
- Comprometimento das propriedades assintóticas dos estimadores.
- Alternativa : Estimação marginal perfilada.

- Considera-se uma distribuição de probabilidade para os traços latentes (não necessariamente no sentido bayesiano).
- Multiplica-se a verossimilhança original por essa densidade porposta e então integra-se com respeito aos traços latentes.
- Maximiza-se, então, essa verossimilhança marginal, com relação aos parâmetros dos itens.
- Suposição usual  $\theta_j|\boldsymbol{\eta} \sim N(0, 1)$ ,  $\boldsymbol{\eta} = (\mu = 0, \psi = 1)$ . Altamente questionável.

# Construção da Verossimilhança Marginal

## ■ Probabilidade Marginal de Resposta

$$\begin{aligned} P(\mathbf{Y}_{.j} = \mathbf{y}_{.j} | \boldsymbol{\zeta}, \boldsymbol{\eta}) \equiv P(\mathbf{Y}_{.j} | \boldsymbol{\zeta}, \boldsymbol{\eta}) &= \int_{\Re} P(\mathbf{Y}_{.j} = \mathbf{y}_{.j} | \theta, \boldsymbol{\zeta}) g(\theta, \boldsymbol{\eta}) d\theta \\ &= \int_{\Re} P(\mathbf{Y}_{.j} = \mathbf{y}_{.j} | \theta, \boldsymbol{\zeta}) g(\theta, \boldsymbol{\eta}) d\theta \\ &= \int_{\Re} P(\mathbf{Y}_{.j} | \theta, \boldsymbol{\zeta}) g(\theta, \boldsymbol{\eta}) d\theta, \end{aligned}$$

em que  $P(\mathbf{Y}_{.j} | \theta, \boldsymbol{\zeta}) = \prod_{i=1}^I P_i^{y_{ij}} Q_i^{1-y_{ij}}$  e  $\boldsymbol{\eta}$  é chamado de vetor de parâmetros populacionais.

# Construção da Verossimilhança Marginal

- Verossimilhança marginal

$$\begin{aligned}L(\zeta, \eta) &= \prod_{j=1}^n P(\mathbf{Y}_{.j}|\zeta, \eta) = \prod_{j=1}^n \int_{\Re} P(\mathbf{Y}_{.j}|\theta, \zeta) g(\theta, \eta) d\theta \\&= \prod_{j=1}^n \int_{\Re} \prod_{i=1}^I P(\mathbf{Y}_{ij}|\theta, \zeta_i) g(\theta, \eta) d\theta.\end{aligned}$$

- Posteriori marginal (considerando  $\eta$  conhecido)

$$p(\zeta|\mathbf{y}, \eta) = \frac{L(\zeta, \eta)p(\zeta)}{\int L(\zeta, \eta)p(\zeta)d\zeta} \quad (1)$$

- Log posteriori marginal

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

- Estimadores moda marginal a posteriori

$$\begin{aligned}\frac{\partial l(\zeta, \eta)}{\partial \zeta_i} &= \frac{\partial}{\partial \zeta_i} \left\{ \sum_{j=1}^n \ln P(\mathbf{Y}_{.j} | \zeta, \eta) \right\} \\ &= \sum_{j=1}^n \frac{1}{P(\mathbf{Y}_{.j} | \zeta, \eta)} \frac{\partial P(\mathbf{Y}_{.j} | \zeta, \eta)}{\partial \zeta_i} + \frac{\ln \partial p(\zeta)}{\partial \zeta}.\end{aligned}$$

■ Mas,

$$\begin{aligned}\frac{\partial P(\mathbf{Y}_j | \zeta, \boldsymbol{\eta})}{\partial \zeta_i} &= \frac{\partial}{\partial \zeta_i} \int_{\Re} P(\mathbf{Y}_j | \theta, \zeta) g(\theta, \boldsymbol{\eta}) d\theta \\&= \int_{\Re} \left( \frac{\partial}{\partial \zeta_i} P(\mathbf{Y}_j | \theta, \zeta) \right) g(\theta, \boldsymbol{\eta}) d\theta \\&= \int_{\Re} \left( \frac{\partial}{\partial \zeta_i} \prod_{h=1}^I P(\mathbf{Y}_{hj} | \theta, b_h) \right) g(\theta, \boldsymbol{\eta}) d\theta \\&= \int_{\Re} \left( \prod_{h \neq i}^I P(\mathbf{Y}_{hj} | \theta, b_h) \right) \left( \frac{\partial}{\partial \zeta_i} P(\mathbf{Y}_{ij} | \theta, \zeta_i) \right) g(\theta, \boldsymbol{\eta}) d\theta \\&= \int_{\Re} \left( \frac{\partial P(\mathbf{Y}_{ij} | \theta, \zeta_i) / \partial \zeta_i}{P(\mathbf{Y}_{ij} | \theta, \zeta_i)} \right) P(\mathbf{Y}_j | \theta, \zeta) g(\theta, \boldsymbol{\eta}) d\theta.\end{aligned}$$

Além disso,

$$\begin{aligned}\frac{\partial P(Y_{ij}|\zeta_i, \theta)}{\partial \zeta_i} &= \frac{\partial}{\partial \zeta_i} \left( P_i^{y_{ij}} Q_i^{1-y_{ij}} \right) \\ &= y_{ij} P_i^{y_{ij}-1} \left( \frac{\partial P_i}{\partial \zeta_i} \right) Q_i^{1-y_{ij}} + P_i^{y_{ij}} (1-y_{ij}) Q_i^{-y_{ij}} \left( \frac{-\partial P_i}{\partial \zeta_i} \right) \\ &= \left[ y_{ij} P_i^{y_{ij}-1} Q_i^{1-y_{ij}} - P_i^{y_{ij}} (1-y_{ij}) Q_i^{-y_{ij}} \right] \left( \frac{\partial P_i}{\partial \zeta_i} \right).\end{aligned}$$

Notemos que o termo entre colchetes vale 1 quando  $y_{ij} = 1$  e -1 quando  $y_{ij} = 0$ , portanto, podemos reescrevê-lo como  $(-1)^{y_{ij}+1}$ . Com isso,

$$\frac{\partial P(Y_{ij}|\zeta_i, \theta)}{\partial \zeta_i} = (-1)^{y_{ij}+1} \left( \frac{\partial P_i}{\partial \zeta_i} \right).$$

Note agora que

$$\frac{(-1)^{y_{ij}+1} P_i Q_i}{P_i^{y_{ij}} Q_i^{1-y_{ij}}} = \begin{cases} Q_i, & \text{se } y_{ij} = 1 \\ -P_i, & \text{se } y_{ij} = 0 \end{cases} = [y_{ij} - P_{ij}].$$

- Dessa forma, temos que

$$\frac{1}{P(\mathbf{Y}_{ij}|\theta, \zeta_i)} \frac{\partial}{\partial \zeta_i} P(\mathbf{Y}_{ij}|\theta, \zeta_i) = \frac{(y_{ij} - P_i)}{P_i Q_i} \left( \frac{\partial P_i}{\partial \zeta_i} \right),$$

Logo,

$$\frac{\partial P(\mathbf{Y}_{.j}|\zeta, \eta)}{\partial \zeta_i} = \int_{\Re} \left[ \frac{(y_{ij} - P_i)}{P_i Q_i} \left( \frac{\partial P_i}{\partial \zeta_i} \right) \right] P(\mathbf{Y}_{.j}|\theta, \zeta) g(\theta, \eta) d\theta$$

- Adicionalmente, vamos supor que  $p(\zeta) = \prod_{i=1}^I p(a_i)p(b_i)p(c_i)$ .

Portanto,


$$a_i \quad : \quad (1 - c_i) \sum_{j=1}^n \int_{\Re} [(y_{ij} - P_i) (\theta - b_i) W_i] g_j^*(\theta) + \frac{\partial p(a_i)}{\partial a_i} = 0$$

$$b_i \quad : \quad -a_i (1 - c_i) \sum_{j=1}^n \int_{\Re} [(y_{ij} - P_i) W_i] g_j^*(\theta) + \frac{\partial p(b_i)}{\partial b_i} = 0$$

$$c_i \quad : \quad \sum_{j=1}^n \int_{\Re} \left[ (y_{ij} - P_i) \frac{W_i}{P_i^*} \right] g_j^*(\theta) + \frac{\partial p(c_i)}{\partial c_i} = 0,$$

em que,

$$g_j^*(\theta) \equiv g(\theta | \mathbf{y}_{.j}, \zeta, \boldsymbol{\eta}) = \frac{P(\mathbf{Y}_{.j} | \theta, \zeta) g(\theta | \boldsymbol{\eta})}{P(\mathbf{Y}_{.j} | \zeta, \boldsymbol{\eta})}.$$



## Forma de quadratura

$$a_i : (1 - c_i) \sum_{j=1}^n \sum_{l=1}^q [(y_{ij} - P_{il}) (\bar{\theta}_l - b_i) W_{il}] g_j^*(\bar{\theta}_l) + \frac{\partial p(a_i)}{\partial \ln a_i} = 0$$

$$b_i : -a_i (1 - c_i) \sum_{j=1}^n \sum_{l=1}^q [(y_{ij} - P_{il}) W_{il}] g_j^*(\bar{\theta}_l) + \frac{\partial \ln p(b_i)}{\partial b_i} = 0$$

$$c_i : \sum_{j=1}^n \sum_{l=1}^q \left[ (y_{ij} - P_{il}) \frac{W_{il}}{P_{il}^*} \right] g_j^*(\bar{\theta}_l) + \frac{\partial \ln p(c_i)}{\partial c_i} = 0$$

## Equações de Mislevy

$$\begin{aligned} a_i & : (1 - c_i) \sum_{l=q}^n [(\bar{r}_{il} - \bar{f}_{il} P_{il}) (\bar{\theta}_l - b_i) W_{il}] + \frac{\partial \ln p(a_i)}{\partial a_i} = 0 \\ b_i & : -a_i (1 - c_i) \sum_{l=1}^q [(\bar{r}_{il} - \bar{f}_{il} P_{il}) W_{il}] + \frac{\partial \ln p(b_i)}{\partial b_i} = 0 \\ c_i & : \sum_{l=1}^q \left[ (\bar{r}_{il} - \bar{f}_{il} P_{il}) \frac{W_{il}}{P_{il}^*} \right] + \frac{\partial \ln p(c_i)}{\partial c_i} = 0, \end{aligned}$$

em que

$$\bar{r}_{il} = \sum_{j=1}^n y_{ij} g_j^* (\bar{\theta}_l) \quad , \quad \bar{f}_{il} = \sum_{j=1}^n g_j^* (\bar{\theta}_l) .$$

$$X_{(i)jl} = \begin{cases} 1, & \text{se o indivíduo } j \text{ responde (é submetido) ao} \\ & \text{item } i \text{ e possui habilidade em torno de } \bar{\theta}_l \\ 0, & \text{caso contrário.} \end{cases}$$

$$\mathcal{E}(F_{il} | \mathbf{Y}_{..}, \boldsymbol{\zeta}, \boldsymbol{\eta}) = \sum_{j=1}^n \mathcal{E}(X_{(i)jl} | \mathbf{Y}_{..}, \boldsymbol{\zeta}, \boldsymbol{\eta}) = \sum_{j=1}^n g_j^*(\bar{\theta}_l) = \bar{f}_{il}$$

e

$$\mathcal{E}(R_{il} | \mathbf{Y}_{..}, \boldsymbol{\zeta}, \boldsymbol{\eta}) = \sum_{j=1}^n \mathcal{E}(y_{ij} X_{(i)jl} | \mathbf{Y}_{..}, \boldsymbol{\zeta}, \boldsymbol{\eta}) = \sum_{j=1}^n y_{ij} g_j^*(\bar{\theta}_l) = \bar{r}_{il}.$$

# Pseudo Algoritmo EM (versão bayesiana)

- Calcula a moda a posteriori na presença de dados faltantes (processo iterativo).
- Aplicação na TRI : considerar as proficiências como os dados não observados.
- Implementação do pseudo algoritmo EM

Seja  $p(\zeta|Y_{..}, \theta)$  a posteriori conjunta do dados completos . Se  $\hat{\zeta}^{(t)}$  é uma estimativa de  $\zeta$  na iteração  $t$ , então os passos EM para obtenção de  $\hat{\zeta}^{(t+1)}$  são

Passo E: Calcular  $E[\ln p(\zeta|Y_{..}, \theta)|Y_{..}, \hat{\zeta}^{(t)}]$

Passo M: Obter  $\hat{\zeta}^{(t+1)}$  que maximiza a função do Passo E.

- No passo M a maximização pode ser feita utilizando o algoritmo Newton-Raphson/Escore de Fisher.

- Considere uma população dividida em  $q$  categorias de proficiência e que dela se extrai uma amostra de tamanho  $n$ .
- Suponha que as proporções no item anterior são dadas por  $\pi = (\pi_1, \dots, \pi_q)'$ .
- Denote por  $\mathbf{f}_i = (f_{i1}, \dots, f_{iq})'$  a quantidade de indivíduos em cada nível de habilidade e  $\mathbf{r}_i = (r_{i1}, \dots, r_{iq})'$  a quantidade daqueles que respondem corretamente ao item  $i$  com nível de habilidade  $l$ , ambos observados na amostra. Além disso  $\mathbf{r} = (\mathbf{r}_1, \dots, \mathbf{r}_I)'$ .

- A probabilidade conjunta que os  $f_{il}$  indivíduos tenham habilidades  $\bar{\theta}_I$ ,  $I = 1, \dots, q$ , é dada pela distribuição multinomial:

$$P(\mathbf{F}_i = \mathbf{f}_i | \boldsymbol{\pi}) \equiv P(\mathbf{f}_i | \boldsymbol{\pi}) = \frac{n_{(i)}!}{\prod_{l=1}^q f_{il}!} \prod_{l=1}^q \pi_j^{f_{il}}, \quad i = 1, \dots, I,$$

- Dados  $f_{il}$  e  $\bar{\theta}_I$ , a probabilidade de ocorrerem  $r_{il}$  acertos ao item  $i$  dentre as  $f_{il}$  tentativas (respostas) por indivíduos com habilidade  $\bar{\theta}_I$  é

$$P(R_{il} = r_{il} | f_{il}, \bar{\theta}_I) \equiv P(r_{il} | f_{il}, \bar{\theta}_I) = \binom{f_{il}}{r_{il}} P_{il}^{r_{il}} Q_{il}^{f_{il}-r_{il}},$$

- A probabilidade conjunta de  $\mathbf{f}$  e  $\mathbf{r}$ , dados  $\bar{\boldsymbol{\theta}} = (\bar{\theta}_1, \dots, \bar{\theta}_q)'$  e  $\pi$ , é

$$\begin{aligned}
 P(\mathbf{F} = \mathbf{f}, \mathbf{R} = \mathbf{r} | \bar{\boldsymbol{\theta}}, \pi) &\equiv P(\mathbf{f}, \mathbf{r} | \bar{\boldsymbol{\theta}}, \pi) = P(\mathbf{r} | \mathbf{f}, \bar{\boldsymbol{\theta}}, \pi)P(\mathbf{f} | \bar{\boldsymbol{\theta}}, \pi) \\
 &= P(\mathbf{r} | \mathbf{f}, \bar{\boldsymbol{\theta}})P(\mathbf{f} | \pi) \\
 &= \left\{ \prod_{i=1}^I \prod_{l=1}^q P(r_{il} | f_{il}, \bar{\theta}_l) \right\} \left\{ \prod_{i=1}^I P(\mathbf{f}_i | \pi) \right\}
 \end{aligned}$$

- Segue que a log posteriori para os dados completos é :

$$\begin{aligned}
 \ln L(\zeta) &= \ln P(\mathbf{f}|\pi) + \sum_{i=1}^I \sum_{l=1}^q \ln P(r_{il}|f_{il}, \bar{\theta}_I) \\
 &= \ln P(\mathbf{f}|\pi) + \sum_{i=1}^I \sum_{l=1}^q \left\{ \ln \begin{pmatrix} f_{il} \\ r_{il} \end{pmatrix} + r_{il} \ln P_{il} + (f_{il} - r_{il}) \ln Q_{il} \right\} \\
 &= C + \sum_{l=1}^q \sum_{i=1}^I \{r_{il} \ln P_{il} + (f_{il} - r_{il}) \ln Q_{il}\} + \ln p(\zeta),
 \end{aligned}$$

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

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

em que

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

- 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,  $\hat{\zeta}_i$ ,  $i = 1, \dots, I$ , 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  $r$  e  $f$  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.

# Abordagem hierárquica

Posteriori marginal

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

Log posteriori marginal

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

# Abordagem hierárquica

Maximizar a log posteriori marginal

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

Parâmetro a

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

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

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

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

com

$$\boldsymbol{h}_{ij} = (P_{il}^* Q_{il}^*)^{-1} \left( \frac{\partial P_{il}}{\partial \zeta_i} \right) = \begin{pmatrix} D(1-c_i)(\bar{\theta}_l - b_i) \\ -D a_i (1-c_i) \\ 1 \\ \bar{P}_{il}^* \end{pmatrix}$$

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

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

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

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

## 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 dos traços latentes;
- ⊖ Não está definido para itens com acerto total ou erro total;
- ⊖ É bastante trabalhoso computacionalmente;
- ⊖ Apresenta problemas na estimação do parâmetro  $c_i$  em alguns casos; deve ser usado somente com um número suficientemente grande de respondentes.

Necessidade do estabelecimento de uma distribuição para  $\theta$ ;

## 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.

- É possível atualizar a distribuição dos traços latentes.
- Método de máxima verossimilhança não-paramétrica (Mislevy (1982)).
- Utiliza as quantidades  $\bar{f}_{il}$  devidamente padronizadas.
- Especificar uma priori em forma de histograma.
- Mistura de normais.
- Os erros-padrão pode ser obtidos através da inversa da Informação de Fisher. Para outras opções veja o manual do mirt.

De posse das estimativas dos parâmetros dos itens constroi-se uma verossimilhança perfilada para estimar as proficiências

$$L(\boldsymbol{\theta}, \hat{\boldsymbol{b}}) = P(\mathbf{Y}_{.j} | \theta_j, \hat{\boldsymbol{\zeta}}) = \prod_{i=1}^I \prod_{j=1}^n \hat{P}_{ij}^{y_{ij}} \hat{Q}_{ij}^{1-y_{ij}},$$

Log posteriori perfilada

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

Equação de estimação bayesiana

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

## Informação de Fisher

$$I(\theta_j) = \sum_{i=1}^I \hat{P}_{ij}^* \hat{Q}_{ij}^* \hat{W}_{ij} \hat{h}_{ij}^2 - \frac{1}{\sigma^2}.$$

## Algoritmo Escore de Fisher

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

em que  $W_{ij} = \frac{P_{ij}^* Q_{ij}^*}{P_{ij} Q_{ij}}$  e  $h_{ij} = a_i(1 - c_i)$

Erros-padrão: inversa da informação de Fisher.

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

Segue que a esperança da posteriori é

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

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

E a variância a posteriori

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

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

Erros-padrão: raíza quadrada da variância a posteriori.

- 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;
- ⊖ Viciado;
- ⊖ Exige cálculos mais complexos do que o método de MV;
- ⊖ 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  $\theta$ .


# Resultados: modelo 1




# Resultados: modelo 1




# Resultados: modelo 1




# Resultados: modelo 1




# Resultados: modelo 1




## Resultados: modelo 2




# Resultados: modelo 2




## Resultados: modelo 2




# Resultados: modelo 2




# Resultados: modelo 2





# Resultados: modelo 2




# Resultados: modelo 2




# Resultados: modelo 3




# Resultados: modelo 3




## Resultados: modelo 3




# Resultados: modelo 3




# Resultados: modelo 3



# Resultados: modelo 3



# Resultados: modelo 3



# Resultados: modelo 3

