

# Modelos politômicos (para respostas politômicas)

Prof. Caio Azevedo

# Aspectos Gerais

- Os modelos policotômicos visam analisar itens que apresentam mais de dois escores possíveis (categorias).
- Basicamente se dividem em duas classes
  - Nominais : as categorias não possuem ordenação entre si - itens de múltipla escolha.
  - Ordinais : as categorias possuem ordenação entre si - itens abertos aos quais são atribuídos algum escore (intervalo  $\{0, 1, \dots, R\}$ ,  $R \in \mathbb{Z}^+$ , escala de Likert etc).

## Exemplo de item nominal

### QUESTÃO 16

Seja  $f(x)$  uma função tal que para todo número real  $x$  temos que  $xf(x - 1) = (x - 3)f(x) + 3$ . Então,  $f(1)$  é igual a

- a) 0.
- b) 1.
- c) 2.
- d) 3.

<http://www.comvest.unicamp.br/wp-content/uploads/2017/02/>



## Exemplo de item gradual

**14.** Sejam  $c$  um número real e  $f(x) = x^2 - 4x + c$  uma função quadrática definida para todo número real  $x$ . No plano cartesiano, considere a parábola dada pelo gráfico de  $y = f(x)$ .

- a) Determine  $c$  no caso em que a abscissa e a ordenada do vértice da parábola têm soma nula e esboce o respectivo gráfico para  $0 \leq x \leq 4$ .
- b) Considere os pontos de coordenadas  $A = (a, f(a))$  e  $B = (b, f(b))$ , onde  $a$  e  $b$  são números reais com  $a < b$ . Sabendo que o ponto médio do segmento  $\overline{AB}$  é  $M = (1, c)$ , determine  $a$  e  $b$ .

<http://www.comvest.unicamp.br/wp-content/uploads/2017/02/>



## Exemplo de item gradual: escala de likert

### **Qual é o nível de importância do trabalho em equipe para seu empregador?**

- Extremamente importante
- Muito importante
- Um pouco importante
- Pouco importante
- Não é importante

https:

[//help.surveymonkey.com/articles/pt\\_BR/kb/Likert-Scales](https://help.surveymonkey.com/articles/pt_BR/kb/Likert-Scales)

## Exemplo de item gradual: escala de likert (altura)

**Na cama, eu frequentemente sinto frio nos pés.**

- Concordo totalmente
- Concordo parcialmente
- Discordo parcialmente
- Discordo totalmente

# Modelo de Resposta Nominal - MRN

$$P_{ijs} = P(Y_{ijs} = 1 | \theta_j, \zeta_i) = \frac{e^{a_{is}(\theta_j - b_{is})}}{\sum_{h=1}^{m_i} e^{a_{ih}(\theta_j - b_{ih})}},$$





- $Y_{ijs} = 1$  se o indivíduo  $j$ , ( $j = 1, 2, \dots, n$ ), escolhe a categoria  $s$ , ( $s = 1, 2, \dots, m_i$ ) do item  $i$ , ( $i = 1, 2, \dots, l$ ) e 0, caso contrário ( $\sum_{h=1}^{m_i} Y_{ijs} = 1$ , as categorias são exaustivas e mutuamente excludentes)
- $\theta_j$  : traço latente do indivíduo  $j$ .

# Modelo de Resposta Nominal - MRN

- $a_{is}$  : está associado à discriminação da categoria  $s$ .
- $b_{is}$  : está relacionado à dificuldade da categoria  $s$ .
- $\zeta_j = (a_1, b_{j1}, \dots, b_{jm_j})'$ . Parâmetros resumo: Pereira, S. R. S. (2012) Contribuições ao Estudo do Modelo de Resposta Nominal, Dissertação de Mestrado, IMECC, Unicamp, <http://repositorio.unicamp.br/handle/REPOSIP/306794>.
- Apresentar exemplos de valores para os parâmetros resumo.



# Representação gráfica do MRN



# Modelo de Resposta Gradual - MRG

- Seja  $Y_{ijs} = 1$  se o indivíduo  $j$ , ( $j = 1, 2, \dots, n$ ), escolhe a categoria  $s$ , ( $s = 0, 1, 2, \dots, m_i$ ) do item  $i$ , ( $i = 1, 2, \dots, l$ ) e 0, caso contrário ( $\sum_{h=1}^{m_i} Y_{ijh} = 1$ , as categorias são exaustivas e mutuamente excludentes)
- Probabilidade do indivíduo  $j$  escolher (receber o escore  $s$ ) a categoria  $s$  ou outra (outro escore) de maior valor:

$$P_{i,s}^+(\theta_j) = \frac{1}{1 + e^{-Da_i(\theta_j - b_{is})}};$$

# Modelo de Resposta Gradual - MRG

em que (de modo que  $\sum_{h=1}^{m_i} P_{ijhs} = 1$ ,  $P_{ijhs}$  é probabilidade do indivíduo  $j$  escolher a categoria  $s$  do item  $i$ ):

$$P_{ijhs} = P_{i,s}(\theta_j) = P_{i,s}^+(\theta_j) - P_{i,s+1}^+(\theta_j)$$

$$P_{i,0}(\theta_j) = P_{i,0}^+(\theta_j) - P_{i,1}^+(\theta_j) = 1 - P_{i,1}^+(\theta_j)$$





$$P_{i,m_i}(\theta_j) = P_{i,m_i}^+(\theta_j) - P_{i,m_i+1}^+(\theta_j) = P_{i,m_i}^+(\theta_j)$$

cont.

$$P_{ijs} = P(Y_{ijs} = 1 | \theta_j, \zeta_i) = \frac{1}{1 + e^{-Da_i(\theta_j - b_{is})}} - \frac{1}{1 + e^{-Da_i(\theta_j - b_{i(s+1)})}}$$

- $\theta_j$  : traço latente do indivíduo  $j$ .
- $a_i$  : está associado à discriminação do item  $i$ .
- $b_{is}$  : está relacionado à dificuldade da categoria  $s$ .
- $\zeta_i = (a_i, b_{i1}, \dots, b_{im_i})$ .

# Representação gráfica do modelo de resposta gradual



# Estimação

- Em geral, há muito mais parâmetros para se estimar do que nos modelos dicotômicos.
- MRN :  $2m_i - 2 + n$  (restrições de identificabilidade:  
 $\sum_{h=1}^{m_i} a_{is} = \sum_{h=1}^{m_i} d_{is} = 0, d_{is} = -a_{is} b_{is}.$ )
- MRG :  $m_i + 1 + n$  (restrições de identificabilidade:  $b_{i0} = 0$ ).
- Adicionalmente,  $\theta \sim D(\eta_\theta)$ , em que  $\mathcal{E}(\theta) = 0, \mathcal{V}(\theta) = 1$ .

# Estimação

- Maior número de iterações requeridas nos processos iterativos.
- Mais pontos de quadratura para se obter estimativas acuradas.
- Espaço paramétrico, em geral, apresenta menos restrições.
  - MRN : sem restrições.
  - MRG :  $a_j > 0$  e  $b_{is} \in \mathbb{R}$ ,  $b_{i1} \leq \dots \leq b_{im_i}$  (além das restrições de identificabilidade).

# Estimação por máxima verossimilhança

- Para cada indivíduo/item (verossimilhança multinomial (Bernoulli multivariada) ( $r = 0,1$ ):

$$P(Y_{ijr} = y_{ijr}, \dots, Y_{ijm_i} = y_{ijm_i} | \theta_j, \zeta_i) = \prod_{s=r}^{m_i} P_{ijs}^{y_{ijs}}.$$

- Maximizar a verossimilhança (conjunta)

$$L(\theta, \zeta) = \prod_{j=1}^n \prod_{i=1}^I \prod_{s=1}^{m_i} P_{ijs}^{y_{ijs}}.$$

- Problemas em se maximizar a verossimilhança genuína (essencialmente os mesmos relativos aos modelos dicotômicos).
- Alternativa : maximizar a verossimilhança marginal.



# Estimação por máxima verossimilhança marginal

- log-verossimilhança marginal

$$\begin{aligned}l(\zeta, \eta) &= \sum_{j=1}^n \ln \int_{\mathfrak{R}} P(\mathbf{Y}_{.j} | \zeta, \theta) g(\theta | \eta) d\theta \\ &= \sum_{j=1}^n \ln P(\mathbf{Y}_{.j} | \zeta, \eta) .\end{aligned}$$

- Função escore

$$\mathbf{S}(\zeta_i) = \sum_{j=1}^n \left\{ \frac{1}{P(\mathbf{Y}_{.j} | \zeta, \eta)} \left( \frac{\partial}{\partial \zeta_i} P(\mathbf{Y}_{.j} | \zeta, \eta) \right) \right\} ,$$

# Estimação por máxima verossimilhança marginal - cont.

mas,

$$\begin{aligned}\frac{\partial}{\partial \zeta_i} P(\mathbf{Y}_{.j} | \zeta, \boldsymbol{\eta}) &= \frac{\partial}{\partial \zeta_i} \left\{ \int_{\mathfrak{R}} P(\mathbf{Y}_{.j} | \zeta, \theta) g(\theta | \boldsymbol{\eta}) d\theta \right\} \\ &= \int_{\mathfrak{R}} \frac{\partial}{\partial \zeta_i} \left\{ \prod_{i=1}^I P_{ij.}^{y_{ij.}} \right\} g(\theta | \boldsymbol{\eta}) d\theta,\end{aligned}$$

com

$$\prod_{i=1}^I P_{ij.}^{y_{ij.}} = \prod_{i=1}^I \prod_{s=1}^{m_i} P_{ijs}^{y_{ijs}} \text{ e } P_{ijs} = P(Y_{ijs} = 1 | \zeta_i, \theta).$$

# Estimação por máxima verossimilhança marginal - cont.

Seguindo, temos que

$$\begin{aligned}\frac{\partial}{\partial \zeta_i} P(\mathbf{Y}_{.j} | \zeta, \eta) &= \int_{\mathfrak{R}} \left\{ \prod_{i' \neq i} P_{ij'}^{y_{ij'}} \right\} \left\{ \frac{\partial P_{ij}^{y_{ij}}}{\partial \zeta_i} \right\} g(\theta | \eta) d\theta \\ &= \int_{\mathfrak{R}} \left\{ \prod_{i=1}^I P_{ij}^{y_{ij}} \right\} \left\{ \prod_{s=1}^{m_i} P_{ijs}^{y_{ijs}} \right\}^{-1} \left\{ \frac{\partial P_{ij}^{y_{ij}}}{\partial \zeta_i} \right\} g(\theta | \eta) d\theta.\end{aligned}$$

Por outro lado  $(y_s, a_s, \phi)$  são quantidades genéricas.

$$\left\{ \prod_s y_s^{a_s} \right\}^{-1} \frac{\partial}{\partial \phi} \left\{ \prod_s y_s^{a_s} \right\} = \sum_s \left\{ \frac{\partial y_s}{\partial \phi} \right\} \left\{ \frac{a_s}{y_s} \right\}, \text{ com } y_s = f(\phi).$$

## Estimação por máxima verossimilhança marginal - cont.

Dessa forma, temos

$$\left\{ \prod_{s=1}^{m_i} P_{ijs}^{y_{ijs}} \right\}^{-1} \left\{ \frac{\partial}{\partial \zeta_i} \left[ \prod_{s=1}^{m_i} P_{ijs}^{y_{ijs}} \right] \right\} = \sum_{s=1}^{m_i} \left\{ \frac{\partial P_{ijs}}{\partial \zeta_i} \right\} \left\{ \frac{y_{ijs}}{P_{ijs}} \right\}.$$

Assim,

$$\frac{\partial}{\partial \zeta_i} P(\mathbf{Y}_{\cdot j} | \zeta, \eta) = \int_{\mathfrak{R}} P(\mathbf{Y}_{\cdot j} | \zeta, \theta) g(\theta | \eta) \left\{ \sum_{s=1}^{m_i} \left[ \frac{y_{ijs}}{P_{ijs}} \left( \frac{\partial P_{ijs}}{\partial \zeta_i} \right) \right] \right\} d\theta.$$

# Estimação por máxima verossimilhança marginal - cont.

Desse modo, vem que

$$\mathbf{S}(\zeta_i) = \sum_{j=1}^n \left\{ \int_{\mathfrak{R}} \mathbf{g}_j^*(\theta) \left\{ \sum_{s=1}^{m_j} \left[ \frac{y_{ijs}}{P_{ijs}} \left( \frac{\partial P_{ijs}}{\partial \zeta_i} \right) \right] \right\} d\theta \right\}.$$

Em que  $\mathbf{g}_j^*(\theta) = \frac{P(\mathbf{Y}_{.j}|\theta, \boldsymbol{\eta}) \mathbf{g}(\theta|\boldsymbol{\eta})}{\int_{\mathfrak{R}} P(\mathbf{Y}_{.j}|\theta, \boldsymbol{\eta}) \mathbf{g}(\theta|\boldsymbol{\eta})}$  o qual compõe os **dados artificiais**.

- Resolução do sistemas de equações de estimação : adaptação do (Pseudo) **algoritmo EM**.

## Desenvolvimento da verossimilhança - Algoritmo EM

- 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  $\boldsymbol{\pi} = (\pi_1, \dots, \pi_q)'$ .
- Denote por  $\mathbf{f}_i = (f_{i1}, \dots, f_{iq})'$  a quantidade de indivíduos em cada nível de habilidade e  $\mathbf{r}_i = (r_{i1}, \dots, r_{iq})'$ ,  $\mathbf{r}_{ik} = (r_{ik1}, \dots, r_{ikm_i})'$  a quantidade daqueles que escolhem a categoria  $s$ ,  $s = 1, \dots, m_i$ , no item  $i$  com nível de traço latente  $l$ , ambos observados na amostra. Além disso  $\mathbf{r} = (\mathbf{r}_1, \dots, \mathbf{r}_I)'$ .

## Desenvolvimento da verossimilhança - Algoritmo EM

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

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

- Dados  $f_{il}$  e  $\bar{\theta}_l$ , a probabilidade de ocorrerem  $r_{ilh}$  escolhas da categoria  $h$ , ao item  $i$  dentre as  $f_{il}$  tentativas (respostas) por indivíduos com traço latente  $\bar{\theta}_l$  (multinomial( $f_{il}, \mathbf{P}_{il}$ )), em que  $\mathbf{P}_{il} = (P_{il1}, \dots, P_{ilm_i})'$ , é dada por

$$P(\mathbf{R}_{il} = \mathbf{r}_{il} | f_{il}, \bar{\theta}_l) \equiv P(r_{il} | f_{il}, \bar{\theta}_l) = \frac{f_{il}}{m_i} \prod_{s=1}^{m_i} P_{ils}^{r_{ils}},$$

# Desenvolvimento da verossimilhança - Algoritmo EM

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

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

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

$$\begin{aligned} \ln L(\zeta) &= \ln P(\mathbf{f} | \pi) + \sum_{i=1}^l \sum_{l=1}^q \ln P(r_{il} | f_{il}, \bar{\theta}_l) \\ &= \ln P(\mathbf{f} | \pi) + \sum_{i=1}^l \sum_{l=1}^q \left\{ \ln f_{il} - \sum_{s=1}^{m_j} \ln r_{ils}! + \sum_{s=1}^{m_j} r_{ils} \ln P_{ils} \right\} \\ &= C + \sum_{l=1}^q \sum_{i=1}^l \sum_{s=1}^{m_j} r_{ils} \ln P_{ils}, \end{aligned}$$



# Desenvolvimento da verossimilhança - Algoritmo EM

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

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

em que

$$\bar{r}_{ils} = E[r_{ils} | \mathbf{Y}_{..}, \zeta] = \sum_{j=1}^n y_{ijs} g_j^*(\bar{\theta}), \quad \bar{f}_{il} = E[f_{il} | \mathbf{Y}_{..}, \zeta] = \sum_{j=1}^n g_j^*(\bar{\theta})$$

$$\text{e } \bar{C} = E[C | \mathbf{Y}_{..}, \zeta].$$

lembrando que  $\sum_{s=1}^{m_i} \bar{r}_{ils} = \bar{f}_{il}$  e

$$g_j^*(\bar{\theta}) = \frac{P(\mathbf{Y}_{.j} | \theta_l, \eta) g(\bar{\theta}_l | \eta)}{\sum_{l=1}^q P(\mathbf{Y}_{.j} | \theta_l, \eta) g(\bar{\theta}_l | \eta)}.$$

# Aplicação do Pseudo algoritmo EM

A proposta de Bock constitui-se no seguinte procedimento

## Passo E

Usar os pontos de quadratura  $\bar{\theta}_l$ , os pesos  $A_l^{(t)}$ ,  $l = 1, \dots, q$  e estimativas provisórias dos parâmetros dos itens,  $\hat{\zeta}_i^{(t)}$ ,  $i = 1, \dots, l$ , para gerar  $g_j^*(\bar{\theta}_l)^{(t)}$  e, posteriormente,  $\bar{r}_{ils}^{(t)}$  e  $\bar{f}_{il}^{(t)}$ ,  $i = 1, \dots, l$ ,  $l = 1, \dots, q$  e  $s = 0, 1, \dots, m_j$ .

## Passo M

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

# Expressões para o MRN

- Inserir as restrições de identificabilidade dos itens (slide 13). Há várias formas de fazê-lo.
- Define-se os parâmetros irrestritos ( $\Gamma_i$ ),  $\alpha_{ih} = a_{i1} - a_{i(h+1)}$ ,  $\delta_{ih} = d_{i1} - d_{i(h+1)}$ , com base nos parâmetros transformados ( $\zeta_i^*$ ),  $d_{is} = -a_{is}b_{is}$ .
- As derivadas necessárias são calculadas em função de  $\Gamma_i = \zeta_i^* \mathbf{S}_i$ .
- Mais detalhes veja Azevedo, C. L. N. (2003). Métodos de estimação na Teoria da Resposta ao Item. Dissertação de Mestardo, IMECC, Unicamp.

[http://www.ime.unicamp.br/~cnaber/Disser\\_METRI.pdf](http://www.ime.unicamp.br/~cnaber/Disser_METRI.pdf)

# Expressões para o MRN

- Vetor escore

$$\mathbf{S}(\boldsymbol{\Gamma}_i) = \sum_{l=1}^q \left\{ \begin{bmatrix} 1 \\ \bar{\theta}_l \end{bmatrix} \otimes \mathbf{T}_i [\bar{\mathbf{r}}_{il} - \bar{f}_{il} \mathbf{P}_{il}] \right\}$$

- Matriz Hessiana (= - Informação de Fisher)

$$\mathbf{H}(\boldsymbol{\Gamma}_i) = \frac{\partial l(\boldsymbol{\Gamma}, \boldsymbol{\eta})}{\partial \boldsymbol{\Gamma}_i \partial \boldsymbol{\Gamma}'_i} = - \sum_{l=1}^q \left\{ \begin{bmatrix} 1 & \bar{\theta}_l \\ \bar{\theta}_l & \bar{\theta}_l^2 \end{bmatrix} \otimes [\mathbf{T}_i \mathbf{W}_{il} \mathbf{T}'_i] \right\}$$

- Erros-padrão (assintóticos): inversa da Informação de Fisher.

## Expressões para o MRN (versão bayesiana)

- priori:  $\Gamma_i \sim N_{m_i-1}(\boldsymbol{\mu}_i, \boldsymbol{\Sigma}_i)$ ,  $\mathbf{V}_i = \boldsymbol{\Sigma}_i^{-1}$ .
- Vetor escore

$$\mathbf{S}(\Gamma_i) = \sum_{l=1}^q \left\{ \begin{bmatrix} 1 \\ \bar{\theta}_l \end{bmatrix} \otimes \mathbf{T}_i [\bar{\mathbf{r}}_{il} - \bar{f}_{il} \mathbf{P}_{il}] \right\} - \mathbf{V}_i (\Gamma_i - \boldsymbol{\mu}_i)$$

- Matriz Hessiana (= - Informação de Fisher)

$$\mathbf{H}(\Gamma_i) = \frac{\partial l(\boldsymbol{\Gamma}, \boldsymbol{\eta})}{\partial \boldsymbol{\Gamma}_i \partial \boldsymbol{\Gamma}'_i} = - \sum_{l=1}^q \left\{ \begin{bmatrix} 1 & \bar{\theta}_l \\ \bar{\theta}_l & \bar{\theta}_l^2 \end{bmatrix} \otimes [\mathbf{T}_i \mathbf{W}_{il} \mathbf{T}'_i] \right\} - \mathbf{V}_i$$

- Erros-padrão (assintóticos): inversa da Informação de Fisher.

# Estimação dos traços latentes

- Máxima verossimilhança perfilada:  $P_{ijs}$  avaliada nas estimativas obtidas para  $\zeta_j$ .
- Verossimilhança perfilada:

$$L(\theta, \hat{\zeta}) = \prod_{j=1}^n \prod_{i=1}^l \prod_{s=1}^{m_i} P_{ijs}^{y_{ijs}}.$$

- Função Escore

$$S(\theta_j) = \sum_{i=1}^l \alpha_i' \mathbf{T}_i [y_{ij.} - \mathbf{P}_{ij.}].$$

- Função hessiana

$$H(\theta_j) = - \sum_{i=1}^l \{ \alpha_i' \mathbf{T}_i \mathbf{W}_{ij} \mathbf{T}_i' \alpha_i \}.$$

# Estimação dos traços latentes

- Algoritmo de Newton -Raphson.

$$\theta_j^{(t)} = \theta_j^{(t-1)} - H(\theta_j^{(t-1)})^{-1} S(\theta_j^{(t-1)})$$

- Erros-padrão (assintóticos): inversa da Informação de Fisher.

# Estimação dos traços latentes

- Priori:  $\theta_j \sim N(0, 1)$ . Posteriori perfilada:  $P_{ij}$ s avaliada nas estimativas obtidas para  $\zeta_i$ .

- Função escore bayesiana

$$S(\theta_j)_B = \sum_{i=1}^I \alpha_i' \mathbf{T}_i [\mathbf{y}_{ij} - \mathbf{P}_{ij}] - \theta_j.$$

- Função hessiana bayesiana

$$H(\theta_j)_B = - \sum_{i=1}^I \{ \alpha_i' \mathbf{T}_i \mathbf{W}_{ij} \mathbf{T}_i' \alpha_i \} - 1.$$

- Algoritmo de Newton -Raphson

$$\theta_j^{(t)} = \theta_j^{(t-1)} - H(\theta_j^{(t-1)})_B^{-1} S(\theta_j^{(t-1)})_B$$

- Erros-padrão (assintóticos): inversa da Informação de Fisher.



# Estimação dos traços latentes

- Esperança a posteriori

$$\mathcal{E} [\theta_j | \mathbf{y}_{.j}, \Gamma, \eta] \approx \frac{\sum_{l=1}^q \bar{\theta}_l P(\mathbf{Y}_{.j} | \bar{\theta}_l, \Gamma) A_l}{\sum_{l=1}^q P(\mathbf{Y}_{.j} | \bar{\theta}_l, \Gamma) A_l}$$

- Variância a posteriori.

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

- Erros-padrão: raiz quadrada da variância a posteriori.

# Expressões para o MRG

- Várias quantidades são iguais ou semelhantes àquelas obtidas para o MRN.
- Vetor escore  $\mathbf{S}(\zeta_i) = (S(a_i), S(b_{i0}), \dots, S(b_{im_i}))'$

$$S(a_i) = \sum_{l=1}^q \sum_{s=0}^{m_i} \left\{ \frac{\bar{r}_{ils}}{P_{ils}} \left[ (\bar{\theta}_j - b_{is}) W_{ils}^+ - (\bar{\theta}_j - b_{i(s+1)}) W_{il(s+1)}^+ \right] \right\}$$

e

$$S(b_{ih}) = a_i \sum_{l=1}^q \left\{ W_{ilh}^+ \left[ \frac{\bar{r}_{il(h-1)}}{P_{il(h-1)}} - \frac{\bar{r}_{il(h)}}{P_{il(h)}} \right] \right\}$$

# Expressões para o MRG

## ■ Informação de Fisher

$$I(\zeta_i) = \begin{bmatrix} I(b_{i1}, b_{i1}) & I(b_{i1}, b_{i2}) & 0 & \dots & \dots & I(b_{i1}, a_i) \\ I(b_{i2}, b_{i1}) & I(b_{i2}, b_{i2}) & I(b_{i2}, b_{i3}) & 0 & \dots & I(b_{i2}, a_i) \\ 0 & I(b_{i3}, b_{i2}) & I(b_{i3}, b_{i3}) & I(b_{i3}, b_{i4}) & \dots & I(b_{i3}, a_i) \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \dots & \dots & I(b_{im_i}, b_{im_i}) & I(b_{im_i}, a_i) \\ I(a_i, b_{i1}) & I(a_i, b_{i2}) & I(a_i, b_{i2}) & \dots & I(a_i, b_{im_i}) & I(a_i, a_i) \end{bmatrix}$$

## Expressões para o MRG

$$I(a_i, a_i) = D^2 \sum_{l=1}^q \sum_{s=0}^{m_i} \left\{ \frac{f_{il}}{P_{ils}} \left[ (\bar{\theta}_l - b_{is}) W_{ils}^+ - (\bar{\theta}_l - b_{i(s+1)}) W_{il(s+1)}^+ \right]^2 \right\},$$

$$I(b_{ih}, b_{ih}) = D^2 a_i^2 \sum_{l=1}^q \left\{ f_{il} \left[ \frac{1}{P_{il(h-1)}} + \frac{1}{P_{ilh}} \right] (W_{ilh}^+)^2 \right\},$$

$$I(b_{ih}, b_{i(h-1)}) = D^2 a_i^2 \sum_{l=1}^q \left\{ \frac{f_{il} W_{ilh}^+ W_{il(h-1)}^+}{P_{il(h-1)}} \right\},$$

$$I(b_{ih}, b_{i(h+1)}) = D^2 a_i^2 \sum_{l=1}^q \left\{ \frac{f_{il} W_{ilh}^+ W_{il(h+1)}^+}{P_{ilh}} \right\}$$

# Expressões para o MRG

$$I(a_i, b_{ih}) = \sum_{l=1}^q f_{il} W_{ilh}^+ \left\{ \frac{1}{P_{il(h-1)}} \left[ (\bar{\theta}_l - b_{i(h-1)}) W_{il(h-1)}^+ - (\bar{\theta}_l - b_{ih}) W_{ilh}^+ \right] - \frac{1}{P_{ilh}} \left[ (\bar{\theta}_l - b_{ih}) W_{ilh}^+ - (\bar{\theta}_l - b_{i(h+1)}) W_{il(h+1)}^+ \right] \right\}.$$

# Estimação dos traços latentes

- Máxima verossimilhança perfilada:  $P_{ijs}$  avaliada nas estimativas obtidas para  $\zeta_j$ .
- Função escore.

$$\begin{aligned} S(\theta_j) &= \sum_{i=1}^I \sum_{s=0}^{m_i} \left\{ \frac{y_{ijs}}{P_{ijs}} \left( \frac{\partial P_{ijs}}{\partial \theta_j} \right) \right\} \\ &= \sum_{i=1}^I \sum_{s=0}^{m_i} \left\{ \frac{a_i y_{ijs} (W_{ijs}^+ - W_{ij(s+1)}^+)}{P_{ijs}} \right\}. \end{aligned}$$

# Estimação dos traços latentes

- Informação de Fisher.

$$I(\theta_j) = a_i^2 \sum_{j=1}^n \sum_{s=0}^{m_i} \left\{ \frac{(W_{ijs}^+ - W_{ij(s+1)}^+)^2}{P_{ijs}} \right\}.$$

- Algoritmo Escore de Fisher  $\theta_j^{(t)} = \theta_j^{(t-1)} + I(\theta_j^{(t-1)})^{-1} S(\theta_j^{(t-1)})$
- Erros-padrão (assintóticos): inversa da Informação de Fisher.

# Recursos computacionais

- Multilog.
  - Modelos dicotômicos e modelo de resposta nominal.
  - MVM, MV, MAP.
  - Facilidades semelhantes às do BILOG-MG.
  - Em sua versão mais recente permite a análise de grupos múltiplos.



# Recursos computacionais

- Pacote mirt (MRN e MRG): opções de parametrização para o MRN.
- $a_{is}(\theta_j - b_{is}) = as_{s-1} * (a_1 * \theta_j) + d_{s-1}$ , em que  $as_0 = 0$ ,  
 $as_{(s-1)} = s - 1$  e  $d_0 = 0$ .

## Recursos computacionais

- No MRN esta parametrização ajuda a identificar o ordenamento empírico das categorias inspecionando os valores de  $ak$ . Valores maiores indicam que a categoria do item está relacionada mais positivamente com a(s) característica(s) do(s) traço(s) latente(s) medidos. Por exemplo, se um item for verdadeiramente ordinal (como numa escala de Likert) e tivesse 4 categorias de resposta, esperaríamos ter  $ak_0 < ak_1 < ak_2 < ak_3$ , em termos de suas estimativas. Se, por outro lado,  $ak_0 > ak_1$ , pareceria que a segunda categoria está menos relacionada ao traço latente do que a primeira e, portanto, a segunda categoria deve ser entendida como a "pontuação mais baixa".

# Estimação bayesiana plena

- Via dados aumentados: Ferreira, E. V. (2014). Modelos da Teoria de Resposta ao Item assimétricos de grupos múltiplos para respostas politômicas nominais e ordinais sob um enfoque bayesiano, Dissertação de Mestrado, Unicamp.  
[http://repositorio.unicamp.br/bitstream/REPOSIP/306788/1/Ferreira\\_EduardoVargas\\_M.pdf](http://repositorio.unicamp.br/bitstream/REPOSIP/306788/1/Ferreira_EduardoVargas_M.pdf)
- Via verossimilhança original: Azevedo (2003)

# Modelo de resposta nominal

Simular  $\theta_j^{(t)} \sim g(\theta_j | \Gamma^{(t-1)}, \mathbf{y}_{\dots})$  (condicional completa), para  $j = 1, \dots, n$  independentemente, considerando como priori uma  $N(\theta_j | \mu_{\theta_j}, \sigma_{\theta_j}^2)$  através de :

- (a) Simular  $\theta_j^{(*)} \sim N(\theta_j^{(t-1)}, \psi_{\theta_j})$
- (b) Calcular o vetor de probabilidades de aceitação  $\theta_j^{(t)} = \theta_j^{(*)}$

$$\pi_j \left( \theta_j^{(t-1)}, \theta_j^{(*)} \right) = \min \left\{ \frac{L(\Gamma^{(t-1)}, \theta_j^{(*)}) \exp \left\{ -\frac{(\theta_j^{(*)} - \mu_{\theta_j})^2}{2\sigma_{\theta_j}^2} \right\}}{L(\Gamma^{(t-1)}, \theta_j^{(t-1)}) \exp \left\{ -\frac{(\theta_j^{(t-1)} - \mu_{\theta_j})^2}{2\sigma_{\theta_j}^2} \right\}}, 1 \right\}$$

- (c) Aceitar cada  $\theta_j^{(t)} = \theta_j^{(*)}$  com probabilidade  $\pi_j$ , caso contrário  $\theta_j^{(t)} = \theta_j^{(t-1)}$

# Modelo de resposta nominal

Simular  $\Gamma_i^{(t)} \sim g(\Gamma_i | \theta^{(t)}, \mathbf{y} \dots)$  (condicional completa), para  $i = 1, \dots, I$

independentemente, considerando como priori  $f(\Gamma_i | \tau_i) \equiv N_{2m_i-2}(\mu_{\Gamma_i}, \Sigma_i)$  através de

(a) Simular  $\Gamma_i^{(*)} \sim N_{2m_i-2}(\Gamma_i^{(t-1)}, \Psi_i)$


(b) Calcular o vetor de probabilidades de aceitação  $\Gamma_i^{(t)} = \Gamma_i^{(*)}$

$$\pi_i \left( \Gamma_i^{(t-1)}, \Gamma_i^{(*)} \right) = \min \{ R_{\Gamma_i}, 1 \}$$

com

$$R_{\Gamma_i} = \frac{L(\Gamma_i^{(*)}, \theta^{(t)}) \exp \left\{ -\frac{1}{2} \left[ \left( \Gamma_i^{(*)} - \mu_{\Gamma_i} \right)' \Sigma_i^{-1} \left( \Gamma_i^{(*)} - \mu_{\Gamma_i} \right) \right] \right\}}{L(\Gamma_i^{(t-1)}, \theta^{(t)}) \exp \left\{ -\frac{1}{2} \left[ \left( \Gamma_i^{(t-1)} - \mu_{\Gamma_i} \right)' \Sigma_i^{-1} \left( \Gamma_i^{(t-1)} - \mu_{\Gamma_i} \right) \right] \right\}}$$

(c) Aceitar cada  $\Gamma_i^{(t)} = \Gamma_i^{(*)}$  com probabilidade  $\pi_i$ , caso contrário  $\Gamma_i^{(t)} = \Gamma_i^{(t-1)}$



## Modelo de resposta gradual

Simular  $\theta_j^{(t)} \sim g(\theta_j | \zeta^{(t-1)}, \mathbf{y})$  (condicional completa), para  $j = 1, \dots, n$  independentemente, considerando como priori uma  $N(\theta_j | \mu_{\theta_j}, \sigma_{\theta_j}^2)$  através de :

- (a) Simular  $\theta_j^{(*)} \sim N(\theta_j^{(t-1)}, \psi_{\theta_j})$
- (b) Calcular o vetor de probabilidades de aceitação  $\theta_j^{(t)} = \theta_j^{(*)}$

$$\pi_j \left( \theta_j^{(t-1)}, \theta_j^{(*)} \right) = \min \left\{ \frac{L(\zeta^{(t-1)}, \theta_j^{(*)}) \exp \left\{ -\frac{(\theta_j^{(*)} - \mu_{\theta_j})^2}{2\sigma_{\theta_j}^2} \right\}}{L(\zeta^{(t-1)}, \theta_j^{(t-1)}) \exp \left\{ -\frac{(\theta_j^{(t-1)} - \mu_{\theta_j})^2}{2\sigma_{\theta_j}^2} \right\}}, 1 \right\}$$

- (c) Aceitar cada  $\theta_j^{(t)} = \theta_j^{(*)}$  com probabilidade  $\pi_j$ , caso contrário  $\theta_j^{(t)} = \theta_j^{(t-1)}$

Simular  $\zeta_i^{(t)} \sim g(\zeta_i | \theta_i^{(t)}, \mathbf{y})$  (condicional completa), para  $i = 1, \dots, I$

independentemente, considerando como priori

$f(\zeta_i | \tau_i) \equiv \log - normal(a_i | \mu_{a_i}, \sigma_{a_i}^2) \times N_{m_i}(\mathbf{b}_i | \mu_{\mathbf{b}_i}, \Sigma_{\mathbf{b}_i})$  através de:

- (a) Simular  $a_i^{(*)} \sim \log - normal(a_i^{(*)} | a_i^{(t-1)}, \psi_{a_i})$ , e  $\mathbf{b}_i^{(*)} \sim N_{m_i}(\mathbf{b}_i^{(*)} | \mathbf{b}_i^{(t-1)}, \Psi_{\mathbf{b}_i})$
- (b) Calcular o vetor de probabilidades de aceitação  $\zeta_i^{(t)} = \zeta_i^{(*)}$

$$\pi_i(\zeta^{(t-1)}, \zeta^{(*)}) = \min\{R_{\zeta_i}, 1\}$$

com

$$R_{\zeta_i} = \frac{L(\zeta_i^{(*)}, \theta^{(t)}) \exp\left\{-\frac{(\ln a_i^{(*)} - \mu_{a_i})^2}{2\sigma_{a_i}^2}\right\} \exp\left\{-\frac{(\ln a_i^{(*)} - a_i^{(t-1)})^2}{2\psi_{a_i}}\right\} [a_i^{(*)}]^2}{L(\zeta_i^{(t-1)}, \theta^{(t)}) \exp\left\{-\frac{(\ln a_i^{(t-1)} - \mu_{a_i})^2}{2\sigma_{a_i}^2}\right\} \exp\left\{-\frac{(\ln a_i^{(t-1)} - a_i^{(*)})^2}{2\psi_{a_i}}\right\} [a_i^{(t-1)}]^2} \times \frac{\exp\left\{-\frac{1}{2} \left[ (\mathbf{b}_i^{(*)} - \mu_{\mathbf{b}_i})' \Sigma_{\mathbf{b}_i}^{-1} (\mathbf{b}_i^{(*)} - \mu_{\mathbf{b}_i}) \right] \right\}}{\exp\left\{-\frac{1}{2} \left[ (\mathbf{b}_i^{(t-1)} - \mu_{\mathbf{b}_i})' \Sigma_{\mathbf{b}_i}^{-1} (\mathbf{b}_i^{(t-1)} - \mu_{\mathbf{b}_i}) \right] \right\}}$$

- (c) Aceitar cada  $\zeta_i^{(t)} = \zeta_i^{(*)}$  com probabilidade  $\pi_i$ , caso contrário  $\zeta_i^{(t)} = \zeta_i^{(t-1)}$

# Referências bibliográficas


- Azevedo, C.L.N. (2003). *Métodos de Estimação na Teoria da Resposta ao Item*. Dissertação de Mestrado. IME-USP.
- Baker, F.B. & Kim, Seock-Ho (2004). *Item Response Theory: Parameter Estimation Techniques*, 2nd edition. New York: Marcel Dekker.




# Voltando ao Exemplo 1

- Voltando ao Exemplo 1: itens de múltipla escolha com cinco alternativas.
- Ajustou-se o modelo de resposta nominal, via MIRT, utilizando o método marginal-perfilado (frequentista para os parâmetros dos itens e via EAP para os traços latentes).

# Distribuição dos traços latentes



# Escores observados e preditos



# Verificação da qualidade de ajuste do modelo

- Curvas características do itens:

<http://www.ime.unicamp.br/~cnaber/CCIMRN.pdf>

- Curvas características dos itens com bandas de confiança:

<http://www.ime.unicamp.br/~cnaber/CCICBMRN.pdf>

- proporções observadas de escolhas por categoria:[http:](http://www.ime.unicamp.br/~cnaber/proportionMRN.pdf)

[//www.ime.unicamp.br/~cnaber/proportionMRN.pdf](http://www.ime.unicamp.br/~cnaber/proportionMRN.pdf)

# Verificação da qualidade de ajuste do modelo

- Proporções observadas e preditas de escolhas por categorias:


<http://www.ime.unicamp.br/~cnaber/proportionCIMRN.pdf>

- curvas características dos itens com probabilidades

esperadas:<http://www.ime.unicamp.br/~cnaber/CCIADMRN.pdf>

- curvas características dos itens com probabilidades esperadas com intervalos de confiança:<http://www.ime.unicamp.br/~cnaber/CCIADCIMRN.pdf>

# Comparação entre as estimativas dos traços latentes



# Comparação entre as estimativas dos traços latentes

