

Métodos de Estimação na Teoria da Resposta ao Item

Caio Lucidius Naberezny Azevedo

cnaber@ime.usp.br

IME-USP

Aspectos Gerais

- Os modelos, em geral, apresentam problemas de identificabilidade.
- Necessidade do uso de métodos numéricos.
- Em geral os métodos bayesianos apresentam melhor desempenho e permitem uma análise mais detalhada.
- Existe um razoável número de métodos (combinações) na literatura.

Método de Máxima Verossimilhança

- Método de Máxima Verossimilhança
 - Consiste em maximizar a verossimilhança com relação aos parâmetros (de interesse).
 - A verossimilhança, basicamente, é a função conjunta da amostra vista como função dos parâmetros.
- Modelo Logístico de 1 parâmetro

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

Contexto Geral

- Considere que n indivíduos respondem a um teste composto por I itens.
- Verossimilhança : pela independência entre as respostas dos diferentes indivíduos e pela independência condicional temos,

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

em que $Q_{ij} = 1 - P_{ij}$, $\boldsymbol{\theta} = (\theta_1, \dots, \theta_n)'$ e $\mathbf{b} = (b_1, \dots, b_j)'$.

Quantidades necessárias

- logverossimilhança

$$l(\boldsymbol{\theta}, \mathbf{b}) = \sum_{j=1}^n \sum_{i=1}^I \{y_{ij} \ln P_{ij} + (1 - y_{ij}) \ln Q_{ij}\},$$

Quantidades necessárias

- logverossimilhança

$$l(\boldsymbol{\theta}, \mathbf{b}) = \sum_{j=1}^n \sum_{i=1}^I \{y_{ij} \ln P_{ij} + (1 - y_{ij}) \ln Q_{ij}\},$$

- Suponha que temos um conjunto de $n=1000$ indivíduos submetidos a um teste de $I = 30$ itens.

Quantidades necessárias

- logverossimilhança

$$l(\boldsymbol{\theta}, \mathbf{b}) = \sum_{j=1}^n \sum_{i=1}^I \{y_{ij} \ln P_{ij} + (1 - y_{ij}) \ln Q_{ij}\},$$

- Suponha que temos um conjunto de $n=1000$ indivíduos submetidos a um teste de $I = 30$ itens.
- Considere que os itens que compõem o instrumento de medida são oriundos de uma banco de itens e, portanto, seus parâmetros são conhecidos.

Quantidades necessárias

- logverossimilhança

$$l(\boldsymbol{\theta}, \mathbf{b}) = \sum_{j=1}^n \sum_{i=1}^I \{y_{ij} \ln P_{ij} + (1 - y_{ij}) \ln Q_{ij}\},$$

- Suponha que temos um conjunto de $n=1000$ indivíduos submetidos a um teste de $I = 30$ itens.
- Considere que os itens que compõem o instrumento de medida são oriundos de uma banco de itens e, portanto, seus parâmetros são conhecidos.
- A verossimilhança passa a ser

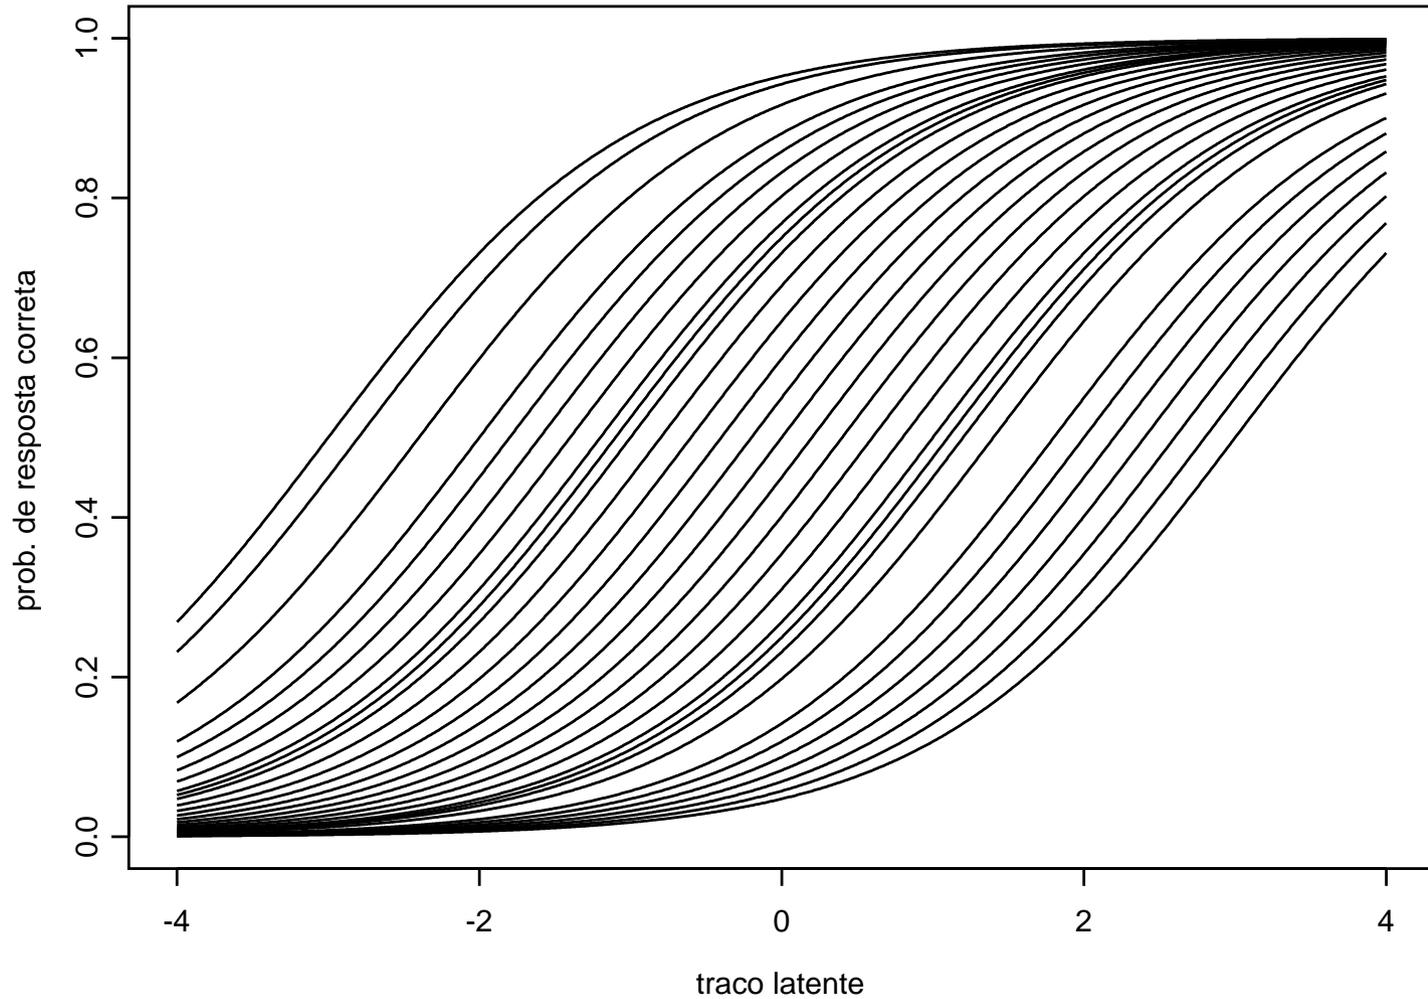
$$l(\boldsymbol{\theta}) = \sum_{j=1}^n \sum_{i=1}^I \{y_{ij} \ln P_{ij} + (1 - y_{ij}) \ln Q_{ij}\}.$$

Descrição dos itens do teste 1

Item	Dificuldade (b)	Item	Dificuldade (b)	Item	Dificuldade (b)
1	-3,0	1	-0,6	1	1,4
2	-2,8	2	-0,4	2	1,8
3	-2,4	3	-0,2	3	2,0
4	-2,0	4	0,0	4	2,2
5	-1,8	5	0,2	5	2,4
6	-1,6	6	0,4	6	2,6
7	-1,4	7	0,6	7	2,8
8	-1,2	8	0,8	8	3,0
9	-1,0	9	1,0	9	-1,1
10	-0,8	10	1,2	10	1,1

Representação Gráfica dos Itens - teste 1

Curvas Características dos 30 itens



Desenvolvimento das equações de estimação

- Objetivo

$$S(\theta_j) = \frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_j} = \frac{\partial}{\partial \theta_j} \sum_{j=1}^n \sum_{i=1}^I \{y_{ij} \ln P_{ij} + (1 - y_{ij}) \ln Q_{ij}\}$$

Desenvolvimento das equações de estimação

- Objetivo

$$S(\theta_j) = \frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_j} = \frac{\partial}{\partial \theta_j} \sum_{j=1}^n \sum_{i=1}^I \{y_{ij} \ln P_{ij} + (1 - y_{ij}) \ln Q_{ij}\}$$

- Desenvolvimento

$$\begin{aligned} \frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_j} &= \sum_{i=1}^I \left\{ y_{ij} \frac{\partial \ln P_{ij}}{\partial \theta_j} + (1 - y_{ij}) \frac{\partial \ln Q_{ij}}{\partial \theta_j} \right\} \\ &= \sum_{i=1}^I \left\{ y_{ij} \frac{1}{P_{ij}} \left(\frac{\partial P_{ij}}{\partial \theta_j} \right) - (1 - y_{ij}) \frac{1}{Q_{ij}} \left(\frac{\partial P_{ij}}{\partial \theta_j} \right) \right\} \\ &= \sum_{i=1}^I \left\{ y_{ij} \frac{1}{P_{ij}} - (1 - y_{ij}) \frac{1}{Q_{ij}} \right\} \left(\frac{\partial P_{ij}}{\partial \theta_j} \right) \\ &= \sum_{i=1}^I \left\{ \frac{y_{ij} - P_{ij}}{P_{ij} Q_{ij}} \right\} \left(\frac{\partial P_{ij}}{\partial \theta_j} \right) \end{aligned}$$

Desenvolvimento das equações de estimação

Mas,

$$\begin{aligned}\frac{\partial P_{ij}}{\partial \theta_j} &= \frac{e^{-(\theta_j - b_i)}}{[1 + e^{-(\theta_j - b_i)}]^2} = \left\{ \frac{1}{1 + e^{-(\theta_j - b_i)}} \right\} \left\{ \frac{e^{-(\theta_j - b_i)}}{1 + e^{-(\theta_j - b_i)}} \right\} \\ &= P_{ij} Q_{ij},\end{aligned}$$

dessa forma,

$$S(\theta_j) = \sum_{i=1}^I [y_{ij} - P_{ij}].$$

- A equação acima não possui solução explícita.
- Alternativa : uso de algoritmos numéricos (Newton-Raphson/Escore de Fisher).

Elementos dos Processos Iterativos

- Para a utilização dos algoritmos anteriores é necessário o cálculo da função Hessiana / Informação de Fisher.

Elementos dos Processos Iterativos

- Para a utilização dos algoritmos anteriores é necessário o cálculo da função Hessiana / Informação de Fisher.
- Função Hessiana

$$H(\theta_j) = \frac{\partial S(\theta_j)}{\partial \theta_j} = - \sum_{i=1}^I \frac{\partial P_{ij}}{\partial \theta_j} = - \sum_{i=1}^I P_{ij} Q_{ij}.$$

Elementos dos Processos Iterativos

- Para a utilização dos algoritmos anteriores é necessário o cálculo da função Hessiana / Informação de Fisher.
- Função Hessiana

$$H(\theta_j) = \frac{\partial S(\theta_j)}{\partial \theta_j} = - \sum_{i=1}^I \frac{\partial P_{ij}}{\partial \theta_j} = - \sum_{i=1}^I P_{ij} Q_{ij}.$$

- Informação de Fisher
Notando que a função Hessiana é não-estocástica temos,

$$I(\theta_j) = \sum_{i=1}^I P_{ij} Q_{ij}.$$

Métodos Iterativos

- Considere $\hat{\theta}_j^{(t)}$ uma estimativa de θ_j na t -ésima iteração.

Newton-Raphson

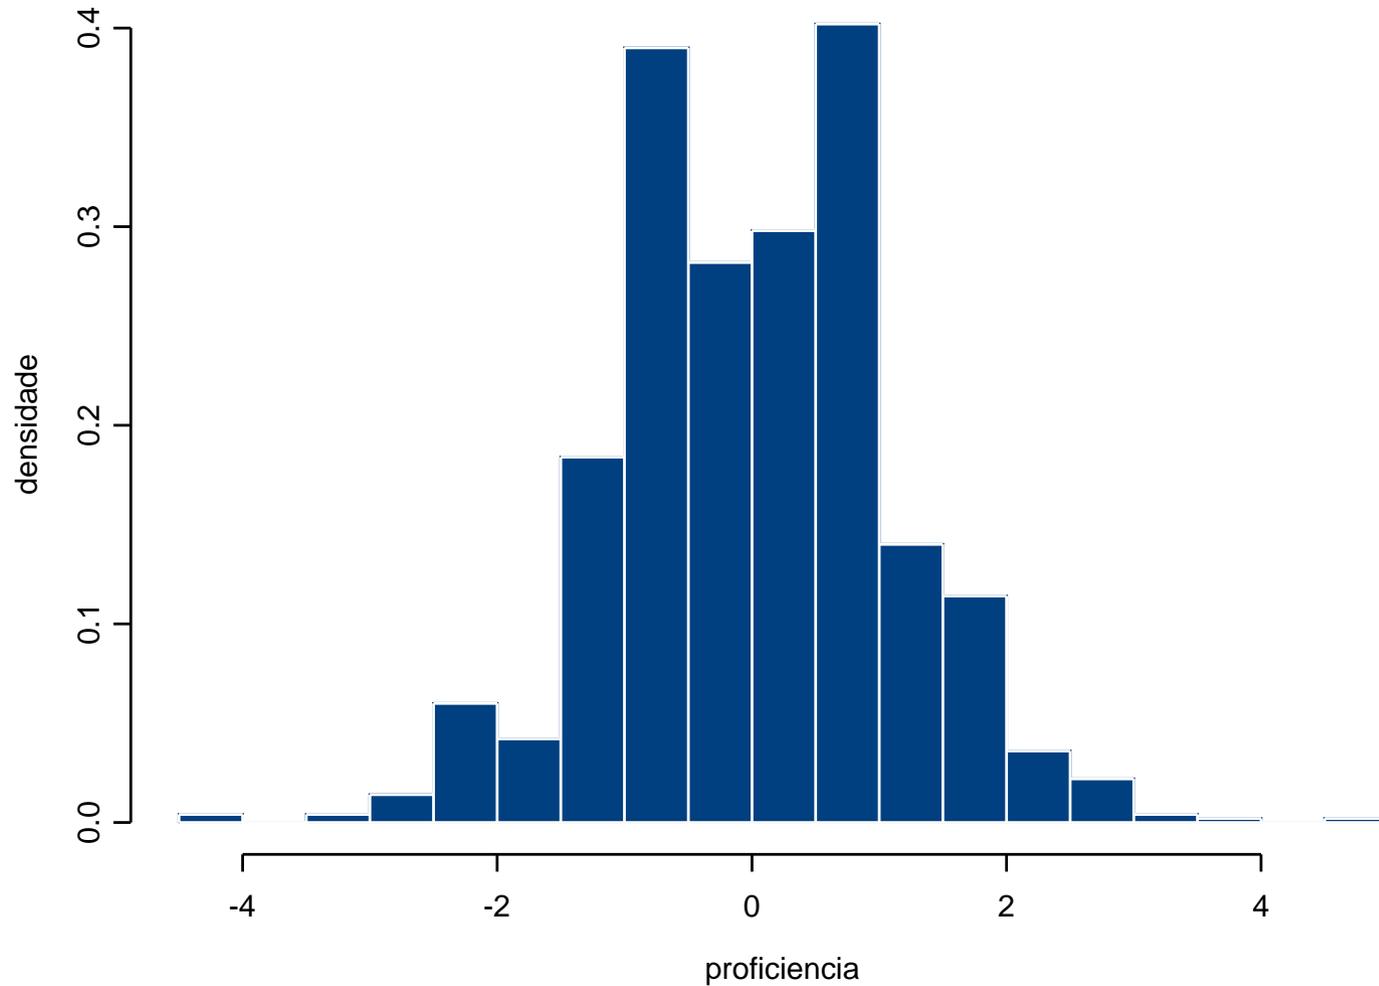
$$\hat{\theta}_j^{(t+1)} = \hat{\theta}_j^{(t)} - \left[H \left(\hat{\theta}_j^{(t)} \right) \right]^{-1} S \left(\hat{\theta}_j^{(t)} \right).$$

Escore de Fisher

$$\hat{\theta}_j^{(t+1)} = \hat{\theta}_j^{(t)} + \left[I \left(\hat{\theta}_j^{(t)} \right) \right]^{-1} S \left(\hat{\theta}_j^{(t)} \right).$$

- Estimativas iniciais : escores padronizados.

Resultados da estimação dos traços latentes



Invariância na estimação das habilidades

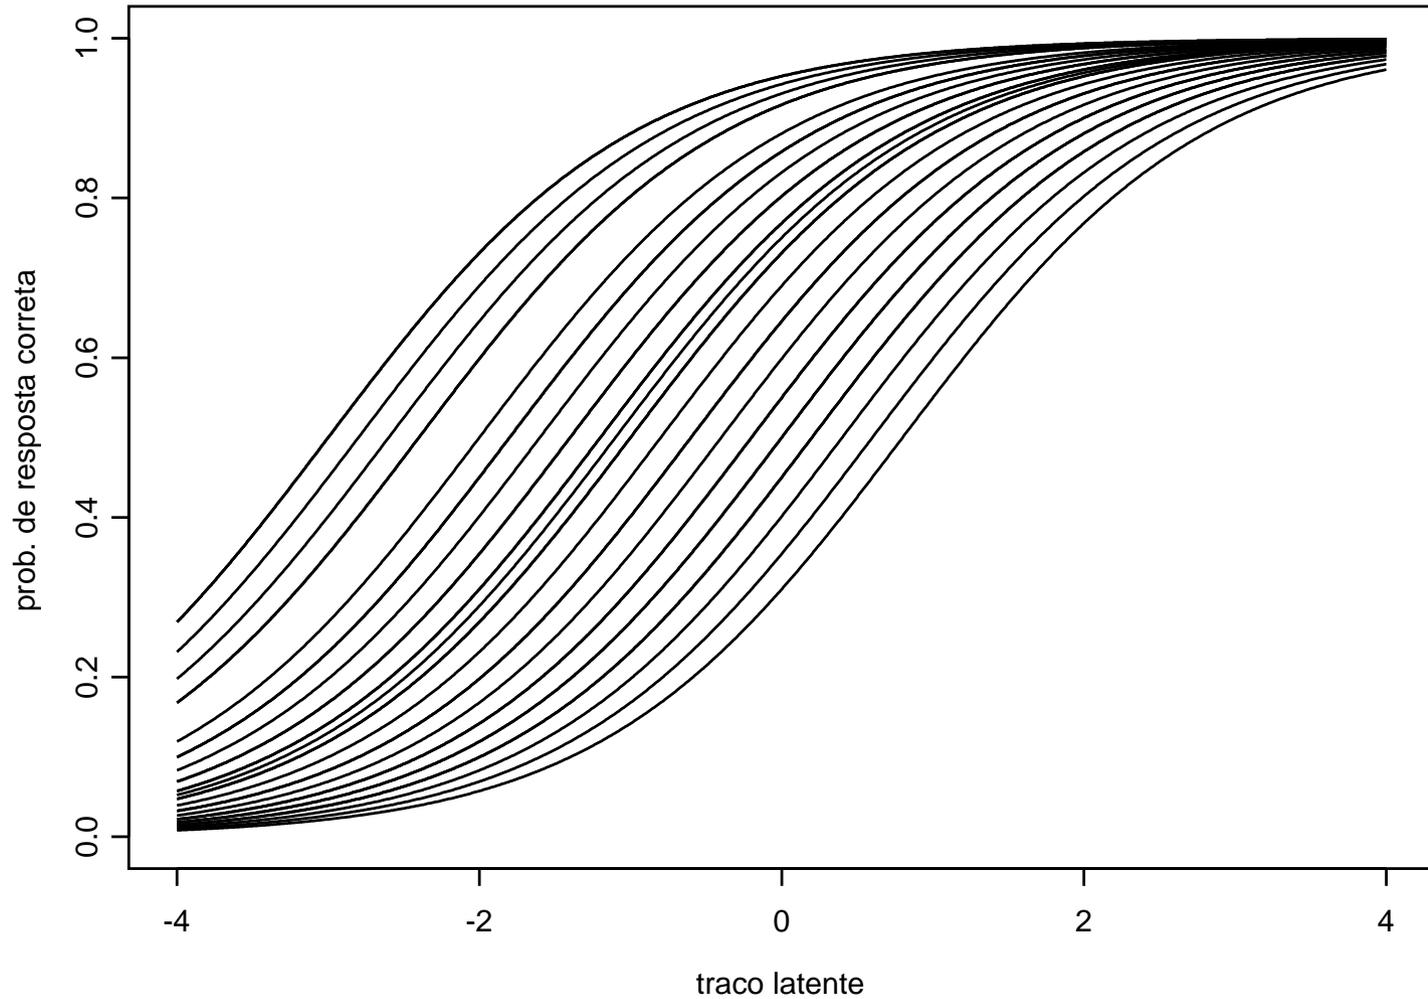
- As estimativas obtidas através da TRI possuem a propriedade da invariância, ou seja, uma vez obtidos os seus valores, estes são únicos.
- Considere a estimação das habilidades dos mesmos indivíduos obtidas a través de dois outros conjuntos de itens (provas).
- O primeiro conjunto é constituído de itens, em geral, mais fáceis que o primeiro conjunto. Já o segundo, é constituído de itens mais difíceis.

Descrição dos itens do teste 2

Item	Dificuldade (b)	Item	Dificuldade (b)	Item	Dificuldade (b)
1	-3,0	1	-0,6	1	-2,4
2	-2,8	2	-0,4	2	-1,8
3	-2,4	3	-0,2	3	-1,4
4	-2,0	4	0,0	4	-1,0
5	-1,8	5	0,2	5	-0,6
6	-1,6	6	0,4	6	-0,2
7	-1,4	7	0,6	7	0,2
8	-1,2	8	0,8	8	-2,6
9	-1,0	9	-1,1	9	-1,2
10	-0,8	10	-3,0	10	0,0

Representação Gráfica dos Itens - teste 2

Curvas Características dos 30 itens

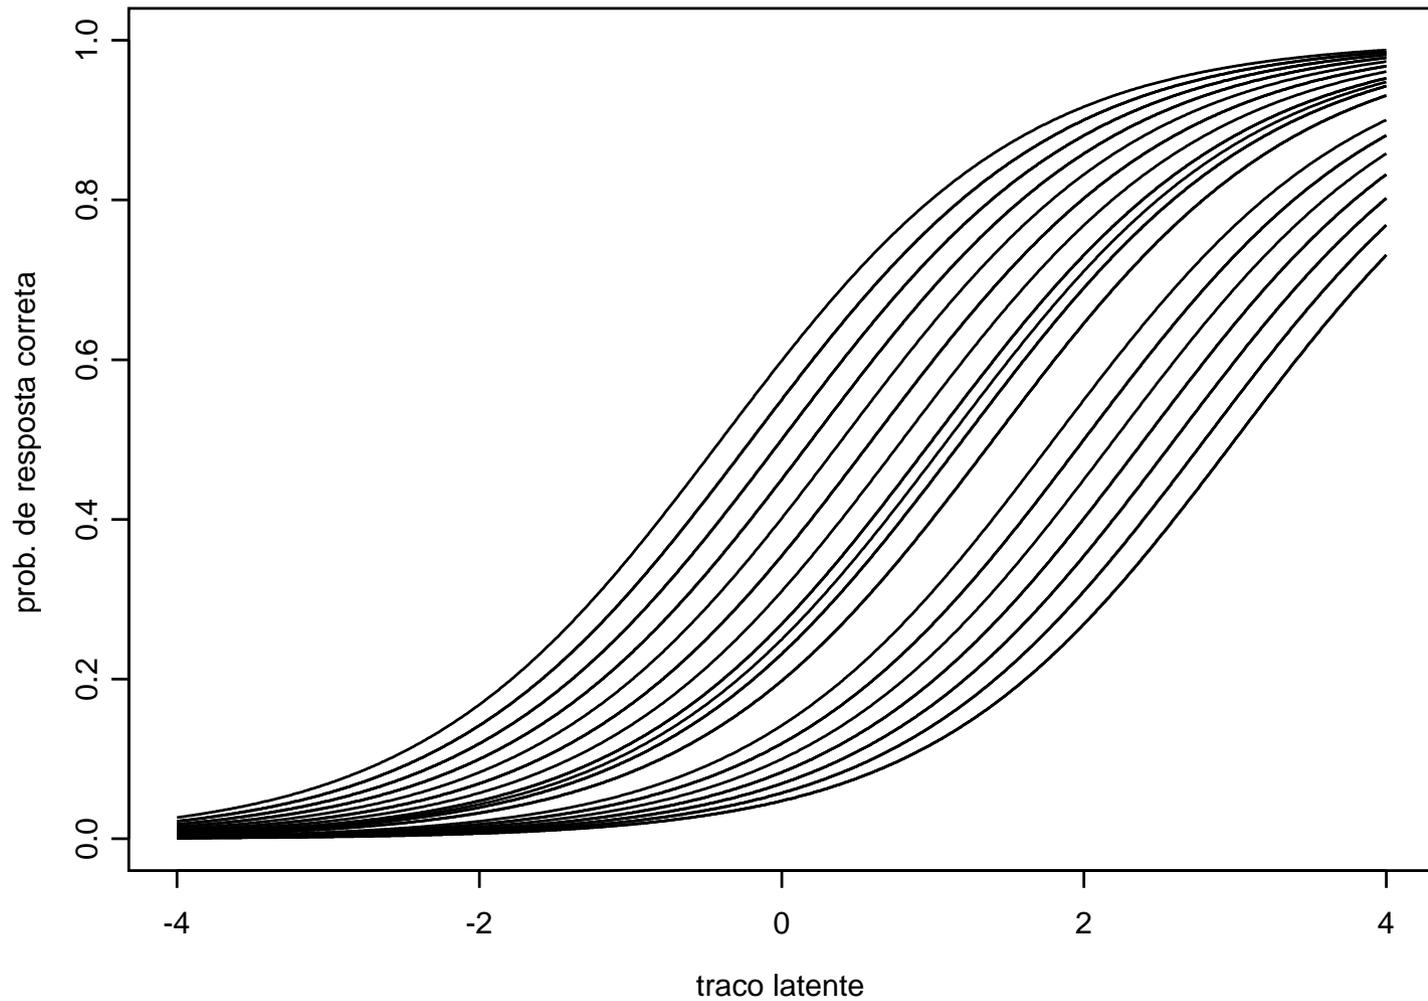


Descrição dos itens do teste 3

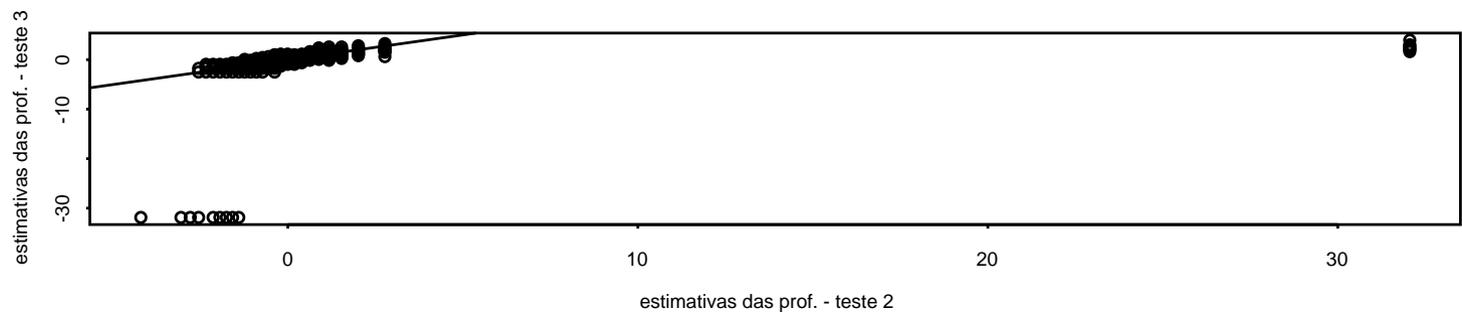
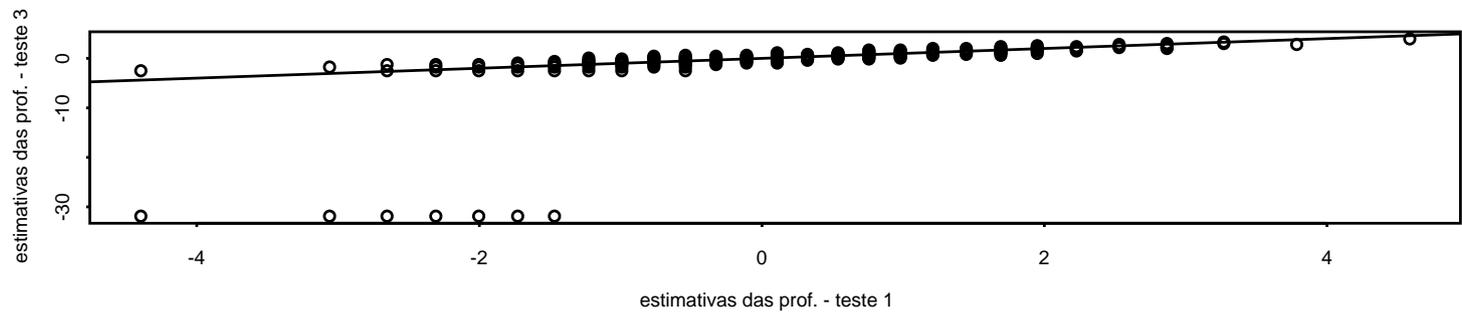
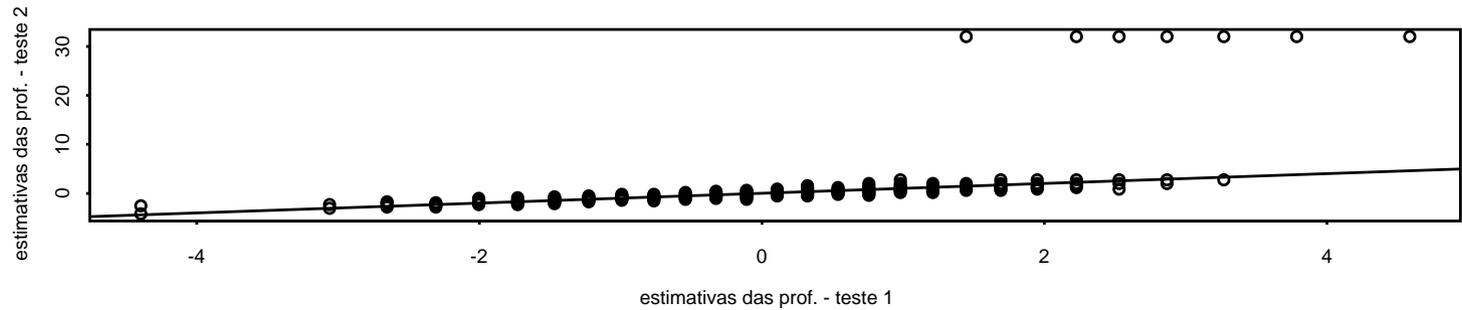
Item	Dificuldade (b)	Item	Dificuldade (b)	Item	Dificuldade (b)
1	1,0	1	1,1	1	0,2
2	1,2	2	1,0	2	0,4
3	1,4	3	1,4	3	0,6
4	1,8	4	2,0	4	0,8
5	2,0	5	2,4	5	0,2
6	2,2	6	2,8	6	0,6
7	2,4	7	3,0	7	0,0
8	2,6	8	2,6	8	-0,2
9	2,8	9	1,2	9	-0,2
10	3,0	10	0,0	10	-0,4

Representação Gráfica dos Itens - teste 3

Curvas Características dos 30 itens



Resultados da estimação dos traços latentes



Habilidades conhecidas - Parâmetros dos itens desconhecidos

- Logverossimilhança

$$l(\mathbf{b}) = \sum_{j=1}^n \sum_{i=1}^I \{y_{ij} \ln P_{ij} + (1 - y_{ij}) \ln Q_{ij}\}.$$

Habilidades conhecidas - Parâmetros dos itens desconhecidos

- Logverossimilhança

$$l(\mathbf{b}) = \sum_{j=1}^n \sum_{i=1}^I \{y_{ij} \ln P_{ij} + (1 - y_{ij}) \ln Q_{ij}\}.$$

- Equações de estimação

$$\begin{aligned} \frac{\partial l(\mathbf{b})}{\partial b_i} &= \sum_{j=1}^n \left\{ y_{ij} \frac{\partial (\ln P_{ij})}{\partial b_i} + (1 - y_{ij}) \frac{\partial (\ln Q_{ij})}{\partial b_i} \right\} \\ &= \sum_{j=1}^n \left\{ y_{ij} \frac{1}{P_{ij}} \left(\frac{\partial P_{ij}}{\partial b_i} \right) - (1 - y_{ij}) \frac{1}{Q_{ij}} \left(\frac{\partial P_{ij}}{\partial b_i} \right) \right\} \\ &= \sum_{j=1}^n \left\{ y_{ij} \frac{1}{P_{ij}} - (1 - y_{ij}) \frac{1}{Q_{ij}} \right\} \left(\frac{\partial P_{ij}}{\partial b_i} \right) \\ &= \sum_{j=1}^n \left\{ \frac{y_{ij} - P_{ij}}{P_{ij} Q_{ij}} \right\} \left(\frac{\partial P_{ij}}{\partial b_i} \right). \end{aligned}$$

Desenvolvimento das equações de estimação

Mas,

$$\begin{aligned}\frac{\partial P_{ij}}{\partial b_i} &= \frac{-e^{-(\theta_j - b_i)}}{[1 + e^{-(\theta_j - b_i)}]^2} = \left\{ \frac{-1}{1 + e^{-(\theta_j - b_i)}} \right\} \left\{ \frac{e^{-(\theta_j - b_i)}}{1 + e^{-(\theta_j - b_i)}} \right\} \\ &= -P_{ij}Q_i\end{aligned}$$

dessa forma,

$$S(b_i) = - \sum_{j=1}^n [y_{ij} - P_{ij}].$$

- A equação acima não possui solução explícita.
- Alternativa : Uso de algoritmos numéricos (Newton-Raphson/Escore de Fisher).

Elementos dos Processos Iterativos

- Para a utilização dos algoritmos anteriores é necessário o cálculo da função Hessiana / Informação de Fisher.

Elementos dos Processos Iterativos

- Para a utilização dos algoritmos anteriores é necessário o cálculo da função Hessiana / Informação de Fisher.
- Função Hessiana

$$H(b_i) = \frac{\partial S(b_i)}{\partial b_i} = - \sum_{j=1}^n \frac{\partial P_{ij}}{\partial b_i} = - \sum_{i=j}^n P_{ij} Q_{ij}.$$

Elementos dos Processos Iterativos

- Para a utilização dos algoritmos anteriores é necessário o cálculo da função Hessiana / Informação de Fisher.
- Função Hessiana

$$H(b_i) = \frac{\partial S(b_i)}{\partial b_i} = - \sum_{j=1}^n \frac{\partial P_{ij}}{\partial b_i} = - \sum_{i=j}^n P_{ij} Q_{ij}.$$

- Informação de Fisher
Notando que a função Hessiana é não-estocástica temos,

$$I(b_i) = \sum_{j=1}^n P_{ij} Q_{ij}.$$

Métodos Iterativos

- Considere $\hat{b}_i^{(t)}$ uma estimativa de θ_j na t -ésima iteração.

Newton-Raphson

$$\hat{b}_i^{(t+1)} = \hat{b}_i^{(t)} - \left[H \left(\hat{b}_i^{(t)} \right) \right]^{-1} S \left(\hat{b}_i^{(t)} \right).$$

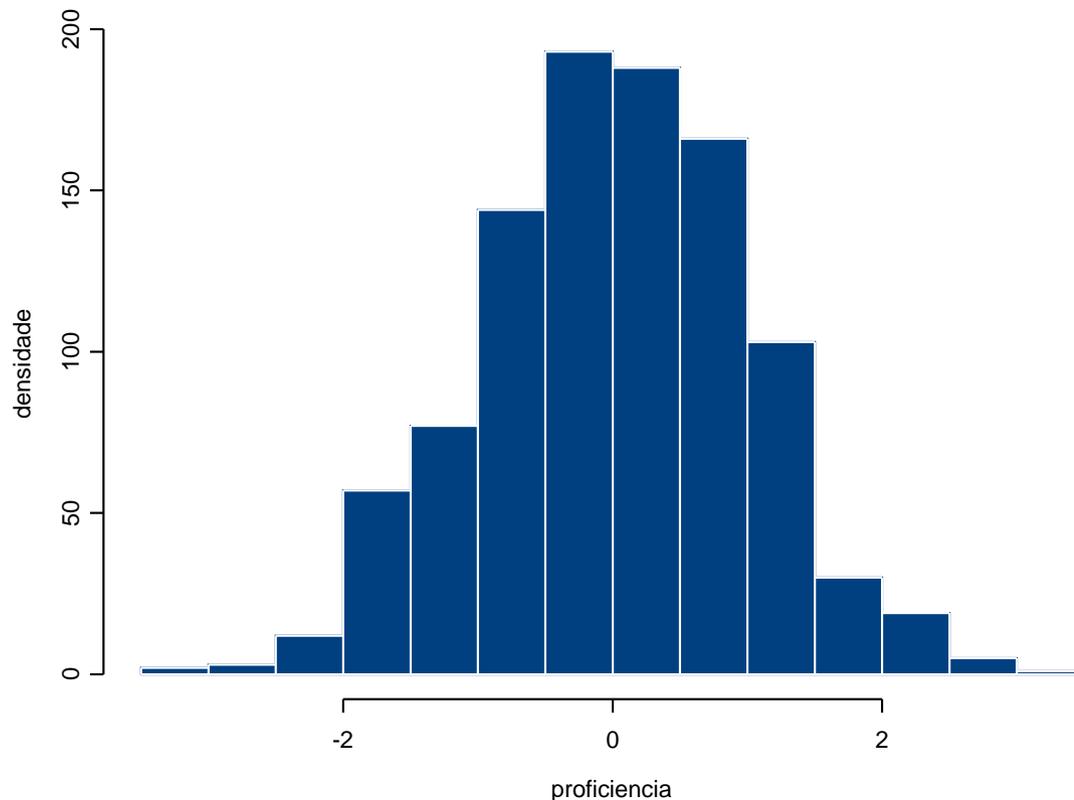
Escore de Fisher

$$\hat{b}_i^{(t+1)} = \hat{b}_i^{(t)} + \left[I \left(\hat{b}_i^{(t)} \right) \right]^{-1} S \left(\hat{b}_i^{(t)} \right).$$

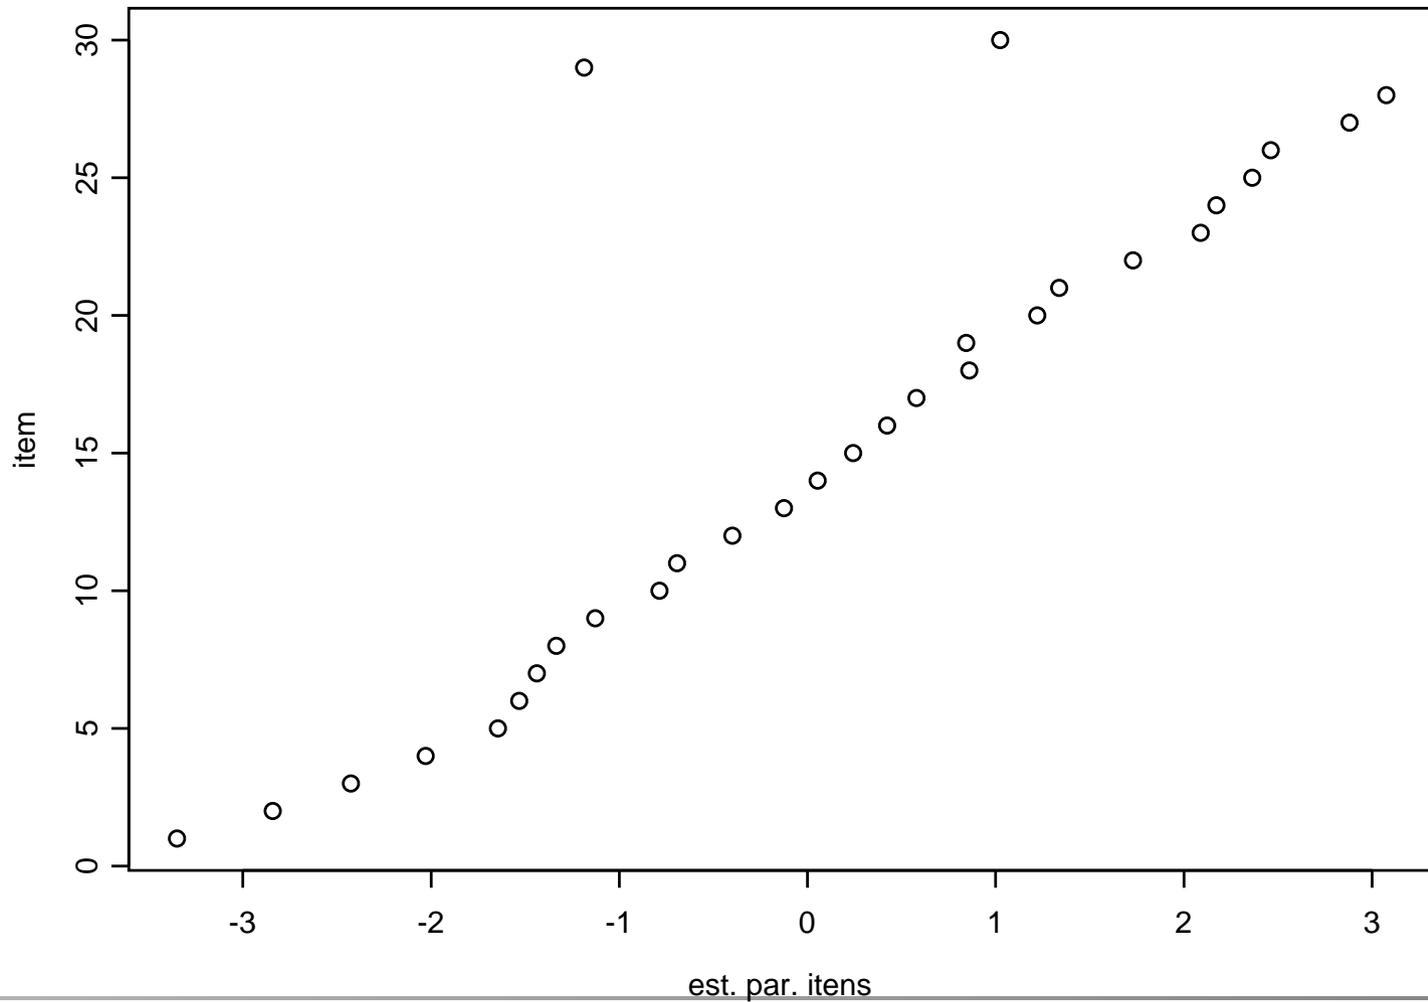
- Estimativas iniciais : proporção de erros padronizadas.

Descrição do teste 4

- Considere um grupo de $n=1000$ indivíduos, com as proficiências conhecidas, submetido a uma prova com $I = 30$ itens (com os parâmetros desconhecidos).

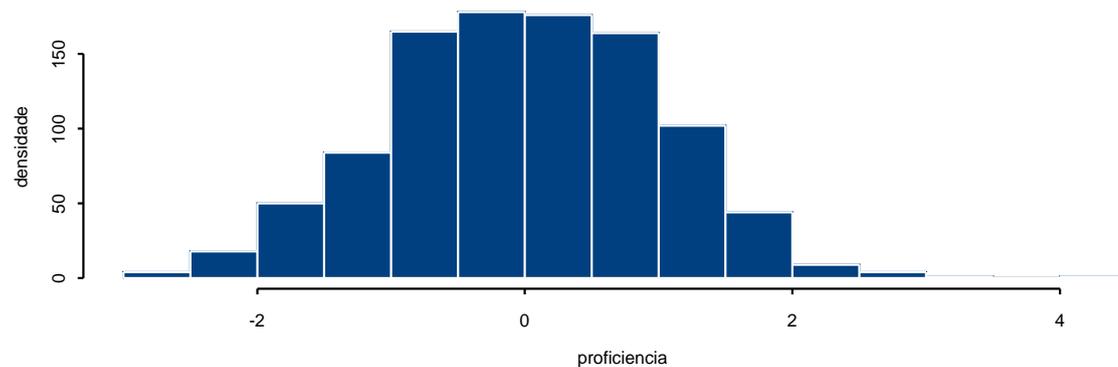
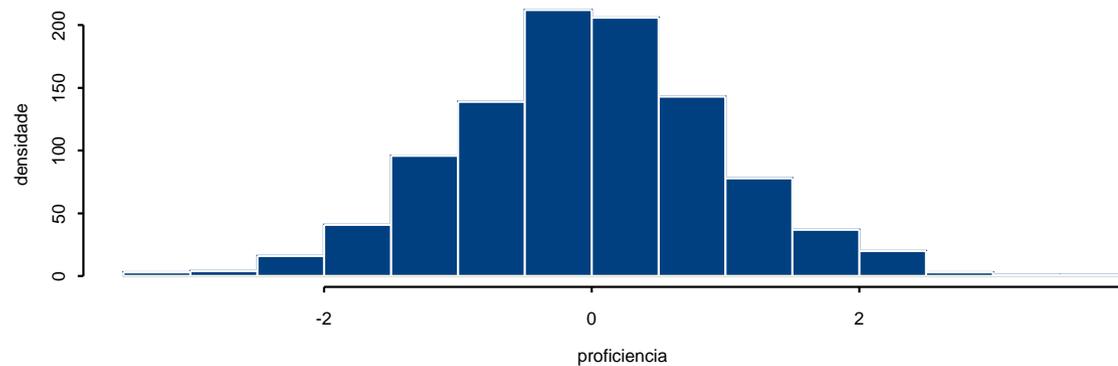


Resultados da estimação dos parâmetros dos itens - teste 4

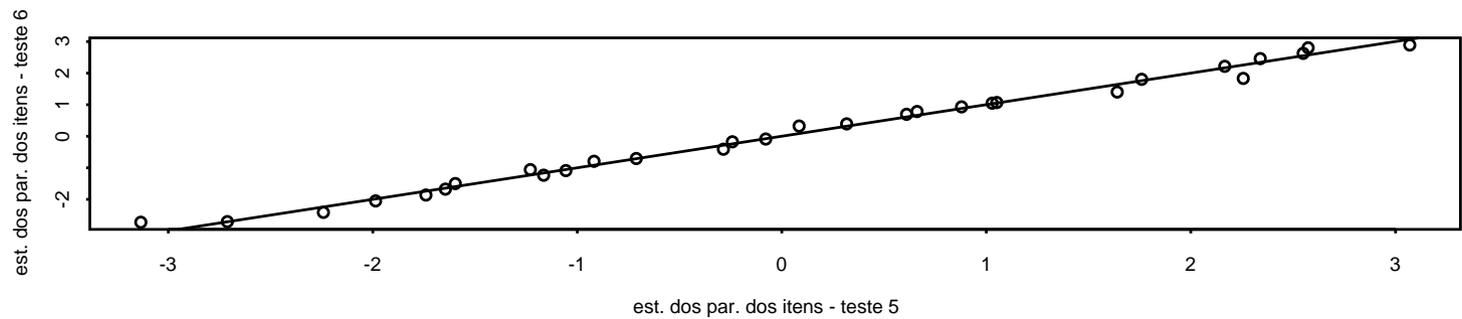
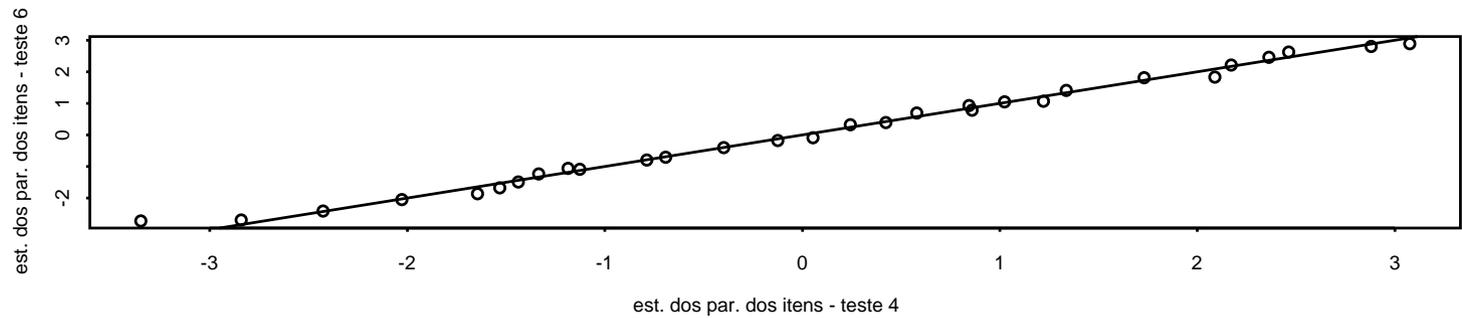
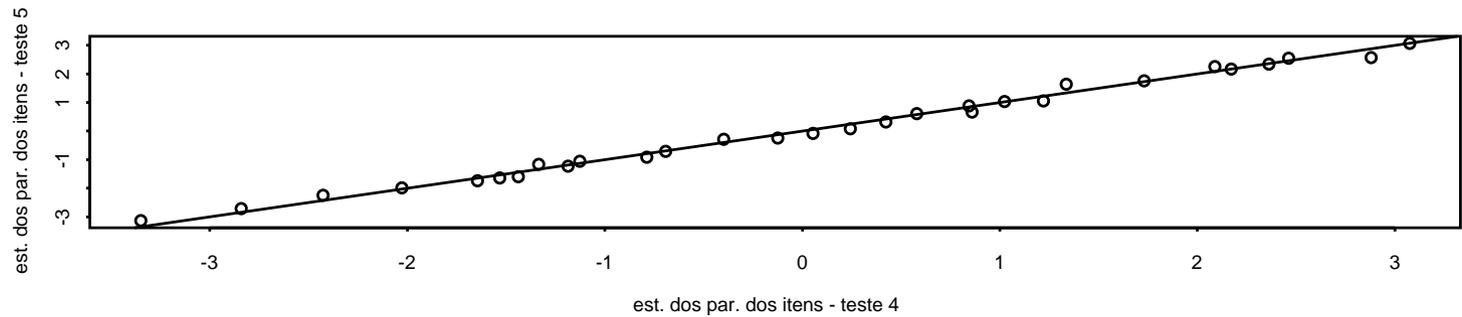


Invariância da estimação dos parâmetros dos itens

- Considere mais dois outros conjuntos de indivíduos (n=1000 cada um), com traços latentes diferentes (do conjunto anterior testes anteriores e entre si).



Resultados da estimação dos parâmetros dos itens - 3 testes



Estimação dos dois conjuntos de parâmetros

- Suponha que temos um conjunto de $n=1000$ indivíduos submetidos a um teste de $I = 30$ itens, em que todos os parâmetros são desconhecidos.
- Temos que estimar, neste caso, 1030 parâmetros.
- Note que, agora, há a necessidade de se estabelecer uma métrica em que os parâmetros irão ser estimados.
- Verossimilhança

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

Considerações do processo de estimação - Máxima Verossimilhança

- Não identificabilidade

$$\begin{aligned} P_{ij} &= \frac{1}{1 + e^{-D(\theta_j - b_i)}} = \frac{1}{1 + e^{-D((\theta_j - d) - (b_i - d))}} \\ &= \frac{1}{1 + e^{-D(\theta_j^* - b_i^*)}} \end{aligned}$$

- Estimação simultânea
 - Inversão de matrizes da ordem de $n \times I$.
 - Comprometimento das propriedades assintóticas dos estimadores.
- Alternativa : Estimação por Máxima Verossimilhança Marginal.

Estimação por Máxima Verossimilhança Marginal

- 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.

Construção da Verossimilhança Marginal

- Probabilidade Marginal de Resposta

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

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

- Verossimilhança marginal

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

Desenvolvimento das expressões

- logverossimilhança

$$l(\mathbf{b}, \eta) = \sum_{j=1}^n \ln \int_{\mathbb{R}} \prod_{i=1}^I P(\mathbf{Y}_{ij} | \theta, b_i) g(\theta, \eta) d\theta.$$

Desenvolvimento das expressões

- logverossimilhança

$$l(\mathbf{b}, \eta) = \sum_{j=1}^n \ln \int_{\mathbb{R}} \prod_{i=1}^I P(\mathbf{Y}_{ij} | \theta, b_i) g(\theta, \eta) d\theta.$$

- Estimadores de Máxima verossimilhança (Marginal)

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

Desenvolvimento das expressões

- Mas,

$$\begin{aligned}\frac{\partial P(\mathbf{Y}_{.j}|\mathbf{b},\eta)}{\partial \mathbf{b}_i} &= \frac{\partial}{\partial \mathbf{b}_i} \int_{\mathcal{R}} P(\mathbf{Y}_{.j}|\theta, \mathbf{b}) g(\theta, \eta) d\theta \\ &= \int_{\mathcal{R}} \left(\frac{\partial}{\partial b_i} P(\mathbf{Y}_{.j}|\theta, \mathbf{b}) \right) g(\theta, \eta) d\theta \\ &= \int_{\mathcal{R}} \left(\frac{\partial}{\partial b_i} \prod_{h=1}^I P(\mathbf{Y}_{hj}|\theta, b_h) \right) g(\theta, \eta) d\theta \\ &= \int_{\mathcal{R}} \left(\prod_{h \neq i}^I P(\mathbf{Y}_{hj}|\theta, b_h) \right) \left(\frac{\partial}{\partial b_i} P(\mathbf{Y}_{ij}|\theta, b_i) \right) g(\theta, \eta) d\theta \\ &= \int_{\mathcal{R}} \left(\frac{\partial P(\mathbf{Y}_{ij}|\theta, b_i) / \partial b_i}{P(\mathbf{Y}_{ij}|\theta, b_i)} \right) P(\mathbf{Y}_{.j}|\theta, \mathbf{b}) g(\theta, \eta) d\theta.\end{aligned}$$

Desenvolvimento das expressões

- Além disso,

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

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,

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

Note agora que

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

Desenvolvimento das expressões

- Dessa forma, temos que

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

Logo,

$$\begin{aligned} \frac{\partial P(\mathbf{Y}_{.j}|\mathbf{b}, \eta)}{\partial b_i} &= \int_{\mathcal{R}} \left[\frac{(y_{ij} - P_i)}{P_i Q_i} \left(\frac{\partial P_i}{\partial b_i} \right) \right] P(\mathbf{Y}_{.j}|\theta, \mathbf{b}) g(\theta, \eta) d\theta \\ &= - \int_{\mathcal{R}} [(y_{ij} - P_i)] P(\mathbf{Y}_{.j}|\theta, \mathbf{b}) g(\theta, \eta) d\theta, \end{aligned}$$

portanto,

$$S(b_i) = \frac{1}{P(\mathbf{Y}_{.j}|\mathbf{b}, \eta)} \frac{\partial P(\mathbf{Y}_{.j}|\mathbf{b}, \eta)}{\partial b_i} = - \sum_{j=1}^n \int_{\mathcal{R}} [y_{ij} - P_i] g_j^*(\theta),$$

em que,

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

Desenvolvimento das expressões

- Forma de quadratura

$$S(b_i) = \sum_{j=1}^n \sum_{l=1}^q [(y_{ij} - P_{il})] g_j^* (\bar{\theta}_l) ,$$

Desenvolvimento das expressões

- Forma de quadratura

$$S(b_i) = \sum_{j=1}^n \sum_{l=1}^q [(y_{ij} - P_{il})] g_j^* (\bar{\theta}_l) ,$$

- Equação de Bock & Aitkin

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

em que

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

Aplicação do Algoritmo EM

- Calcula estimativas de máxima verossimilhança na presença de dados faltantes (processo iterativo).
- Aplicação na TRI : considerar as proficiências como os dados não observados.
- Implementação do algoritmo EM
Seja $L(\mathbf{b}|\mathbf{Y}., \boldsymbol{\theta})$ a densidade conjunta do dados completos (verossimilhança) .
Se $\hat{\mathbf{b}}^{(t)}$ é uma estimativa de \mathbf{b} na iteração t , então os passos EM para obtenção de $\hat{\mathbf{b}}^{(t+1)}$ são
Passo E: Calcular $E[\ln L(\mathbf{b}|\mathbf{Y}., \boldsymbol{\theta})|\mathbf{Y}., \hat{\mathbf{b}}^{(t)}]$
Passo M: Obter $\hat{\mathbf{b}}^{(t+1)}$ que maximiza a função do Passo E.
- No passo M a maximização pode ser feita utilizando o algoritmo Newton-Raphson/Escore de Fisher.

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 $\pi = (\pi_1, \dots, \pi_q)'$.
- 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 $\bar{\theta}_l$, $l = 1, \dots, q$, é dada pela distribuição multinomial:

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

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

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

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 π , é

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

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

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

Desenvolvimento da verossimilhança

- Algoritmo EM

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

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

em que

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

- 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.

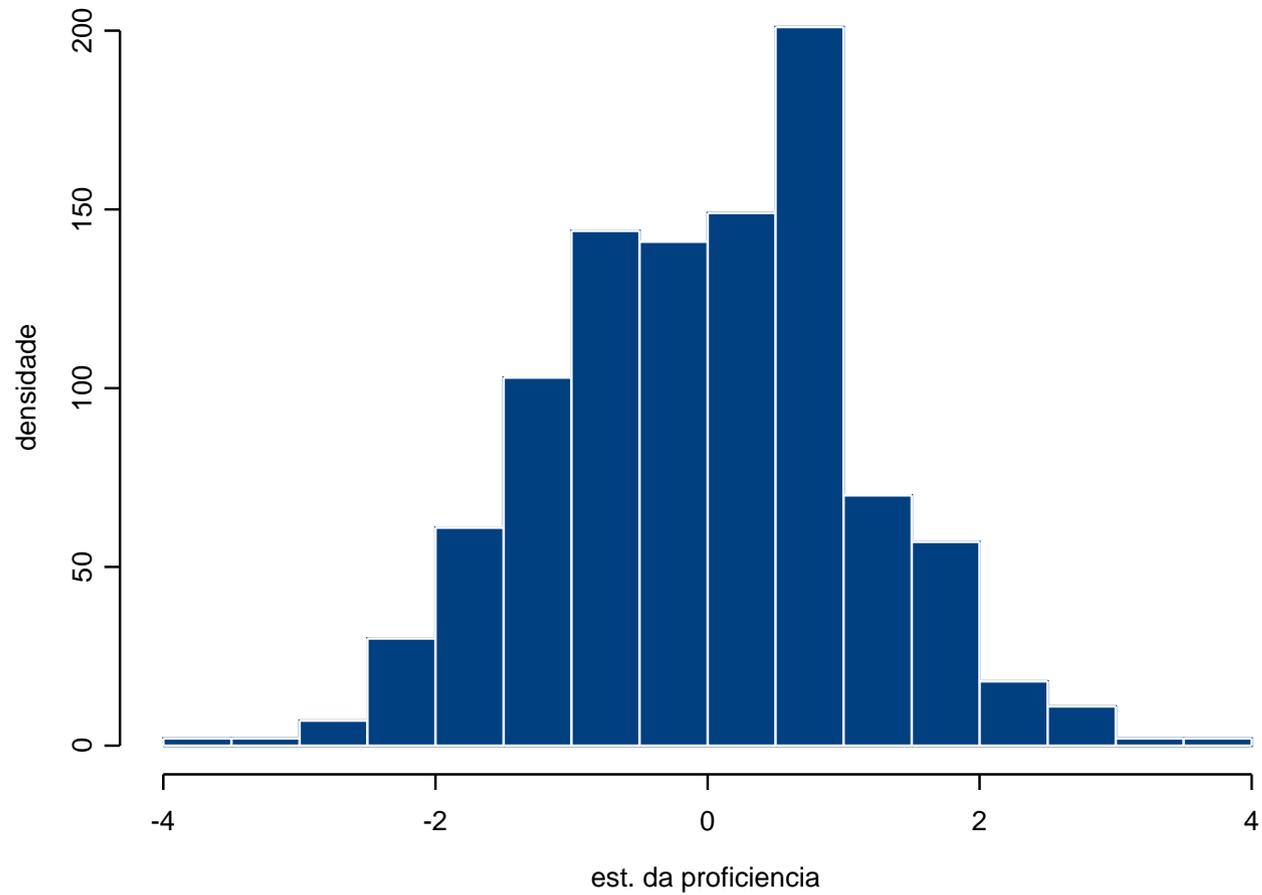
Estimação das habilidades - Máxima Verossimilhança Perfilada

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

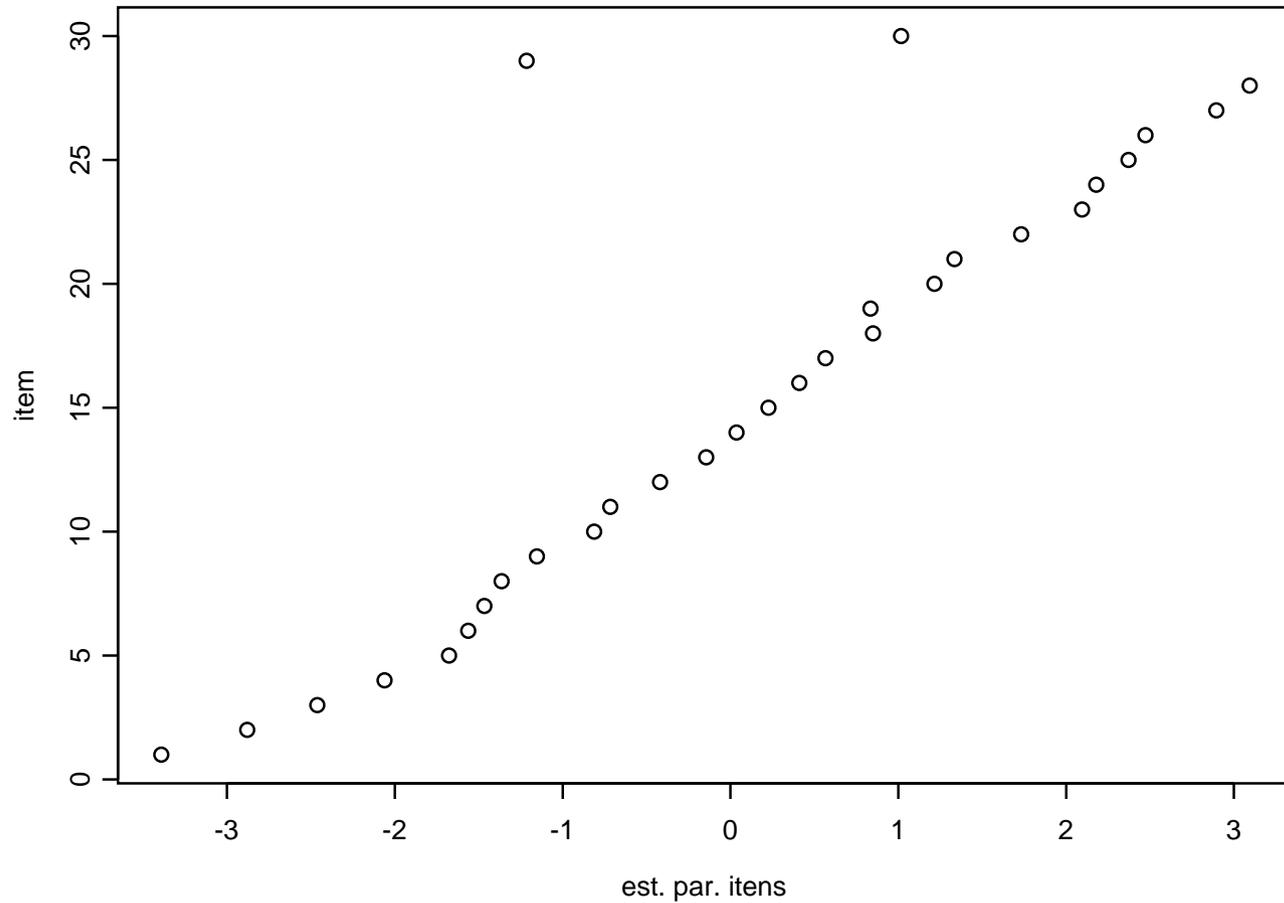
$$L(\boldsymbol{\theta}, \hat{\mathbf{b}}) = \prod_{i=1}^I \prod_{j=1}^n \hat{P}_{ij}^{y_{ij}} \hat{Q}_{ij}^{1-y_{ij}},$$

- Assim, utiliza-se a verossimilhança acima, tal como no caso em que os parâmetros dos itens eram conhecidos.
- Considere um teste com $n=1000$ indivíduos e $I=30$ itens, com todos os parâmetros desconhecidos.

Resultado do processo de estimação

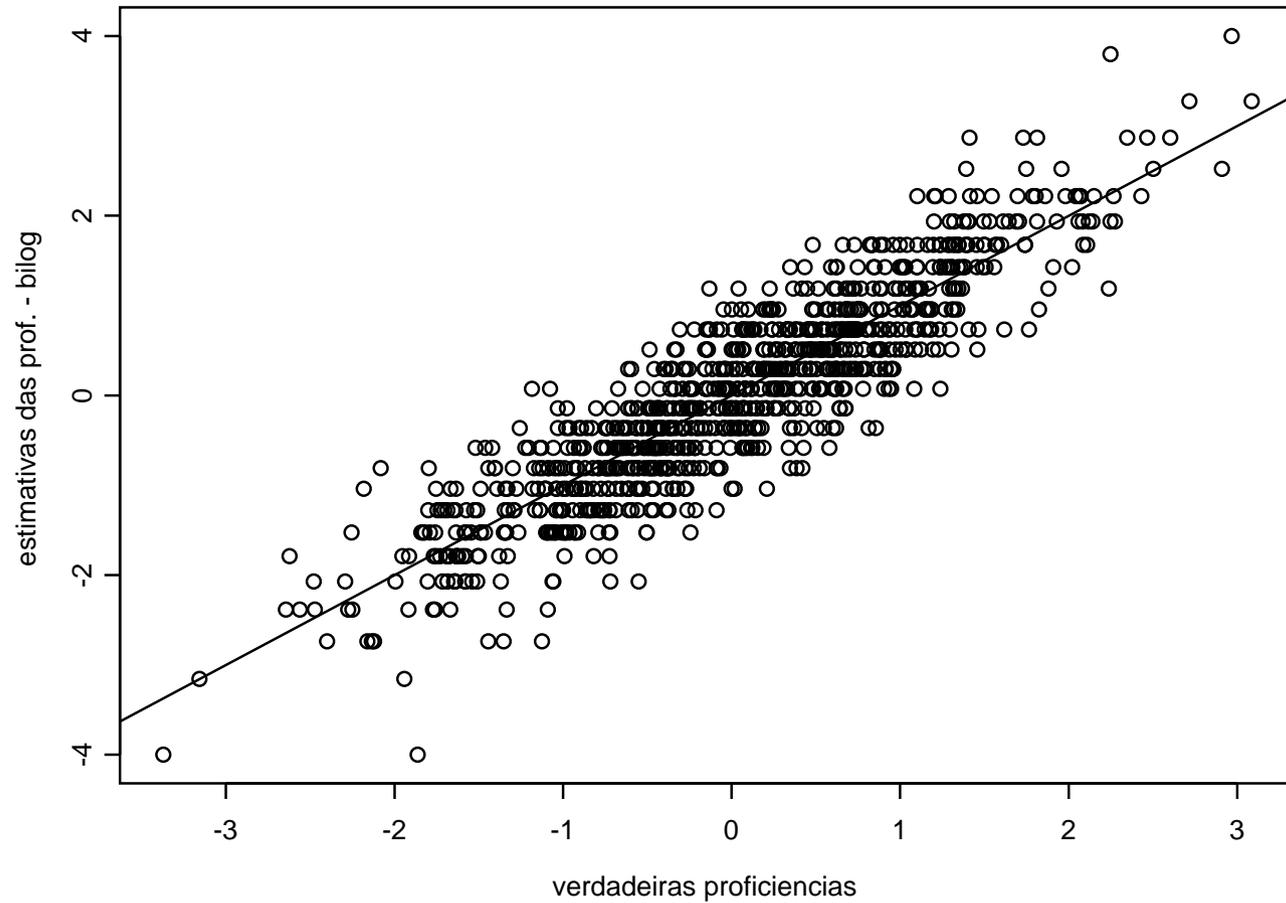


Resultado do processo de estimação



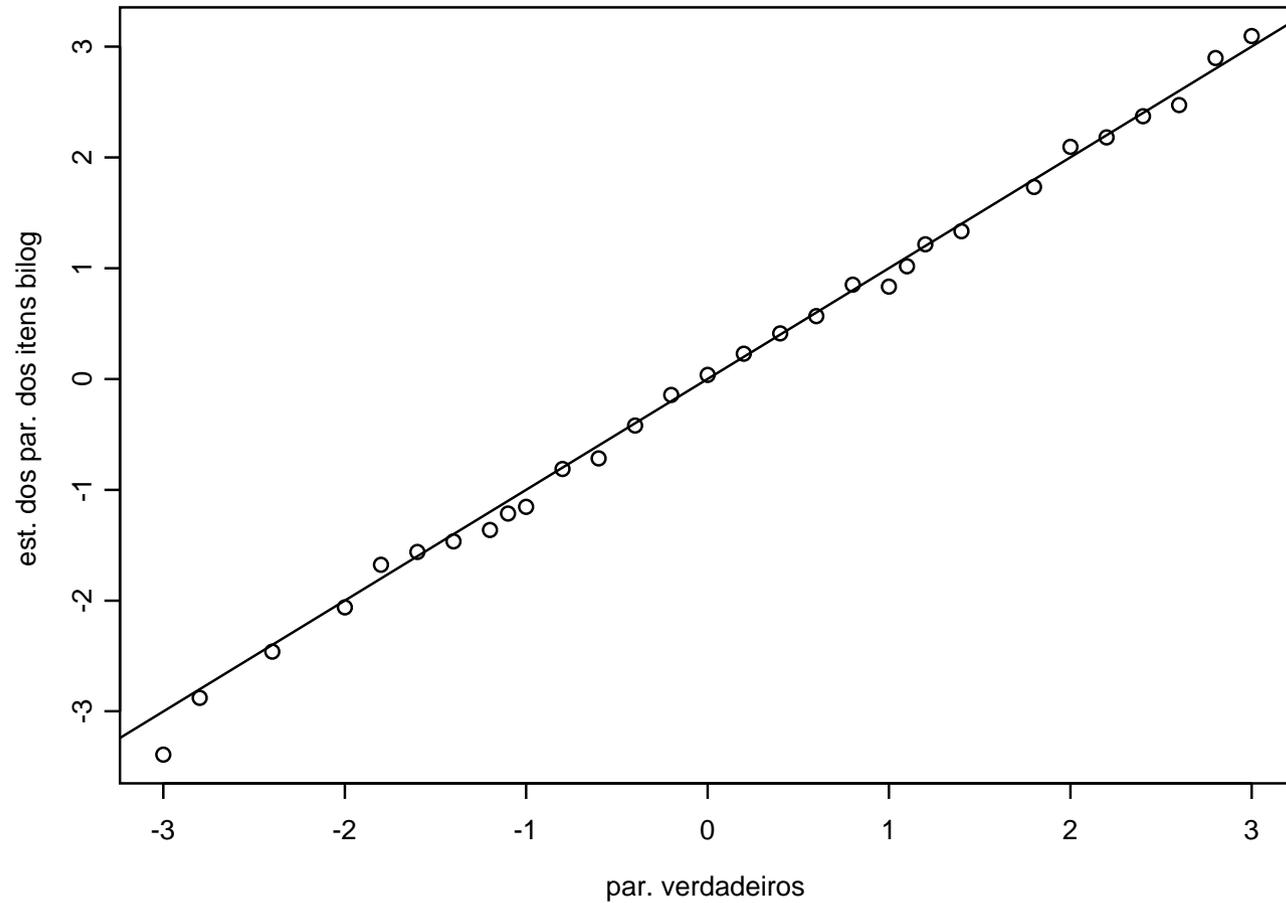
Resultado do processo de estimação

- comp. com os verd. valores



Resultado do processo de estimação

- comp. com os verd. valores



Comparação das verossimilhanças

