

Métodos de estimação: máxima verossimilhança e marginal-perfilados frequentistas

Prof. Caio Azevedo

Aspectos Gerais

- Elevado número de parâmetros.
- Falta de identificabilidade.
- Dificuldades na estimação dos parâmetros.
- Dificuldades na verificação do ajuste dos modelos.
- Ausência de metodologias apropriadas para a seleção de modelos não encaixados.

- Os traços latentes são variáveis aleatórias: $\theta_j \stackrel{i.i.d.}{\sim} N(0, 1)$
(identificabilidade)
- Suposições (inferência) :
 - O tempo para se responder o teste é necessário.
 - As informações necessárias para se modelar a probabilidade de resposta são: o traço latente do indivíduo e os parâmetros do item.
 - Apenas uma dimensão do traço latente é necessária para se modelar tal probabilidade (unidimensionalidade).
 - Dados omissos são oriundos de mecanismos de não resposta não informativos.
 - As probabilidades de seleção de cada indivíduo que compõe a amostra são as mesmas.
 - Condicionadas as informações citadas anteriormente, as probabilidades de resposta são independentes.

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)).

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

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

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,

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

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

Quantidades necessárias

- logverossimilhança

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

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

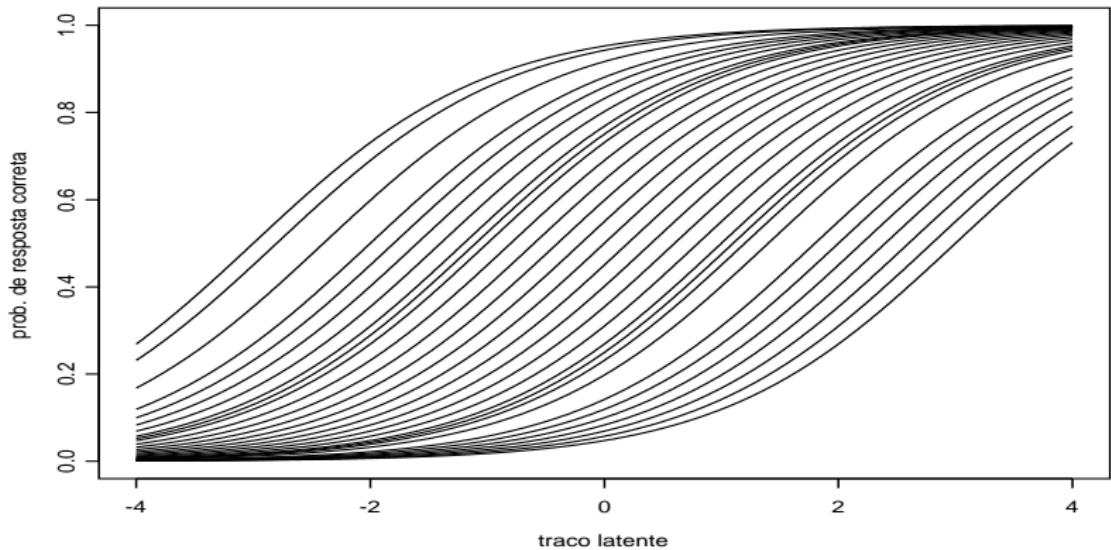
$$I(\theta) = \sum_{j=1}^n \sum_{i=1}^l \{y_{ij} \ln P_{ij} + (1 - y_{ij}) \ln Q_{ij}\}.$$

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

■ Função escore

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

■ Desenvolvimento

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

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.
- 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

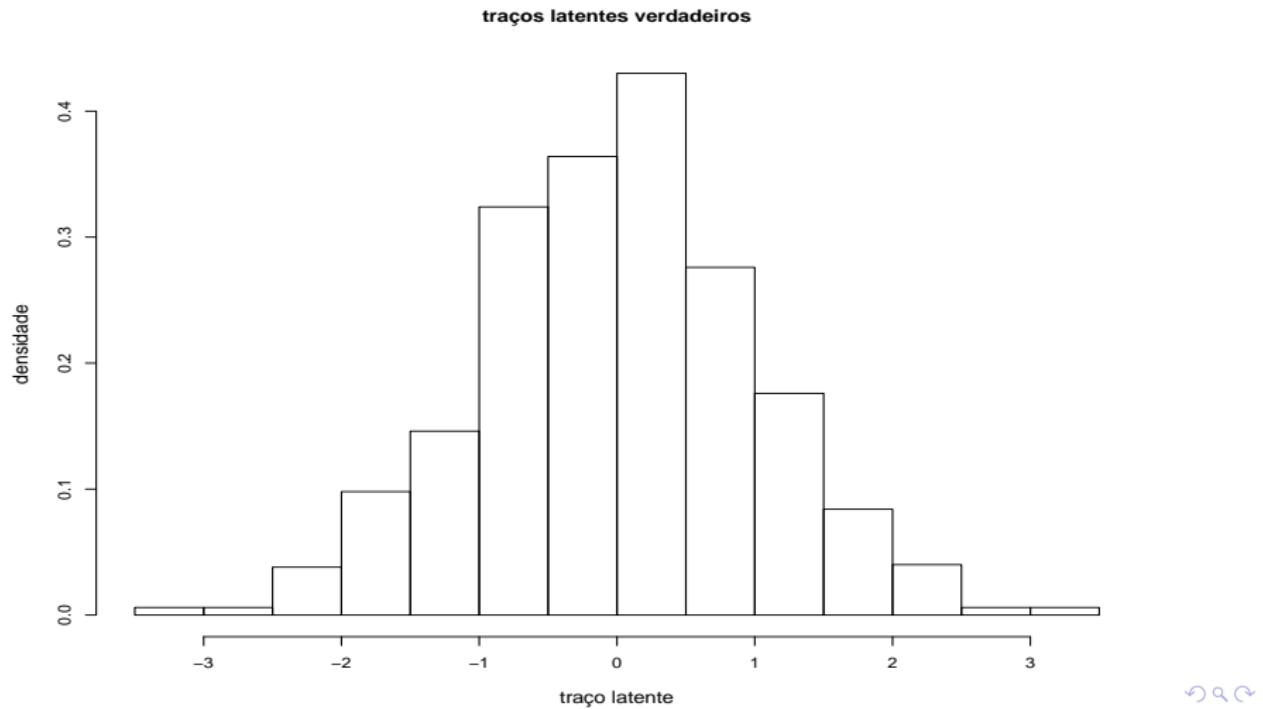
$$\hat{\theta}_j^{(t+1)} = \hat{\theta}_j^{(t)} - [H(\hat{\theta}_j^{(t)})]^{-1} S(\hat{\theta}_j^{(t)}).$$

Escore de Fisher

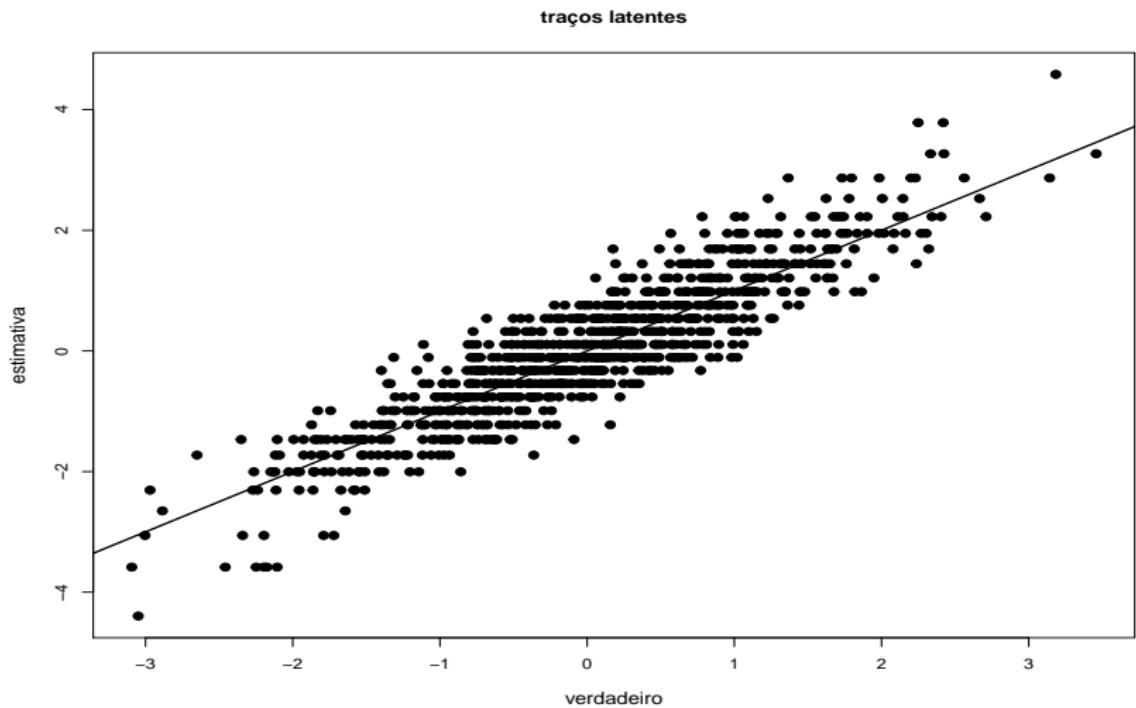
$$\hat{\theta}_j^{(t+1)} = \hat{\theta}_j^{(t)} + [I(\hat{\theta}_j^{(t)})]^{-1} S(\hat{\theta}_j^{(t)}).$$

- Estimativas iniciais : escores padronizados. Erros-padrão: inversa da informação de Fisher.

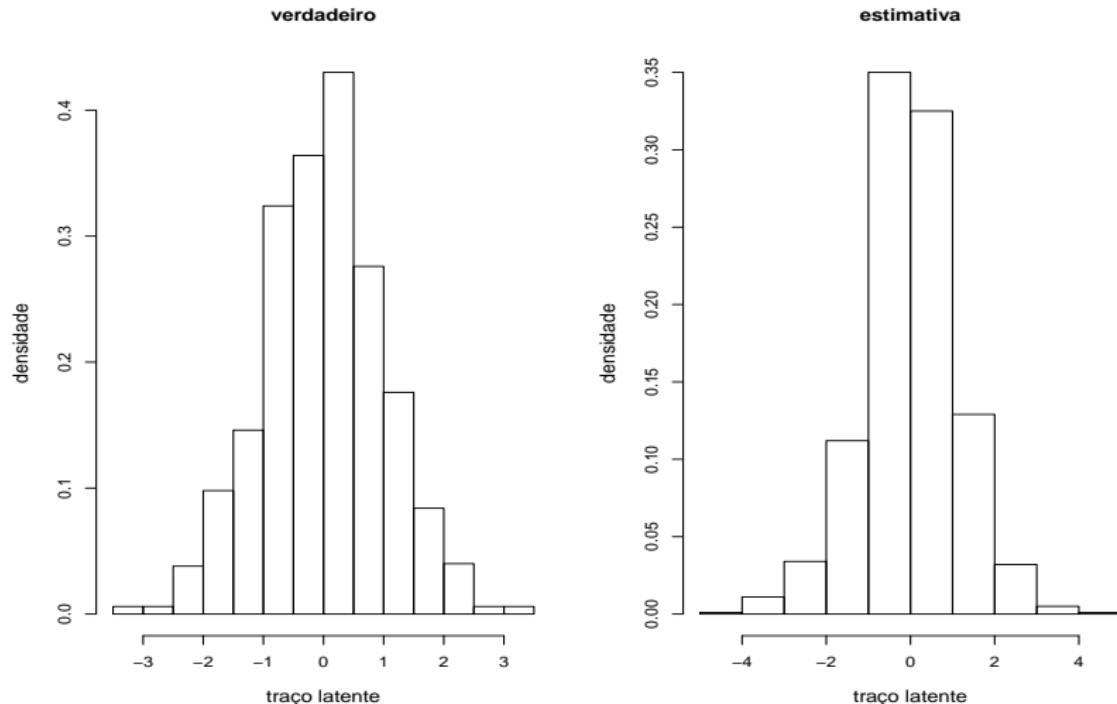
Traços latentes verdadeiros



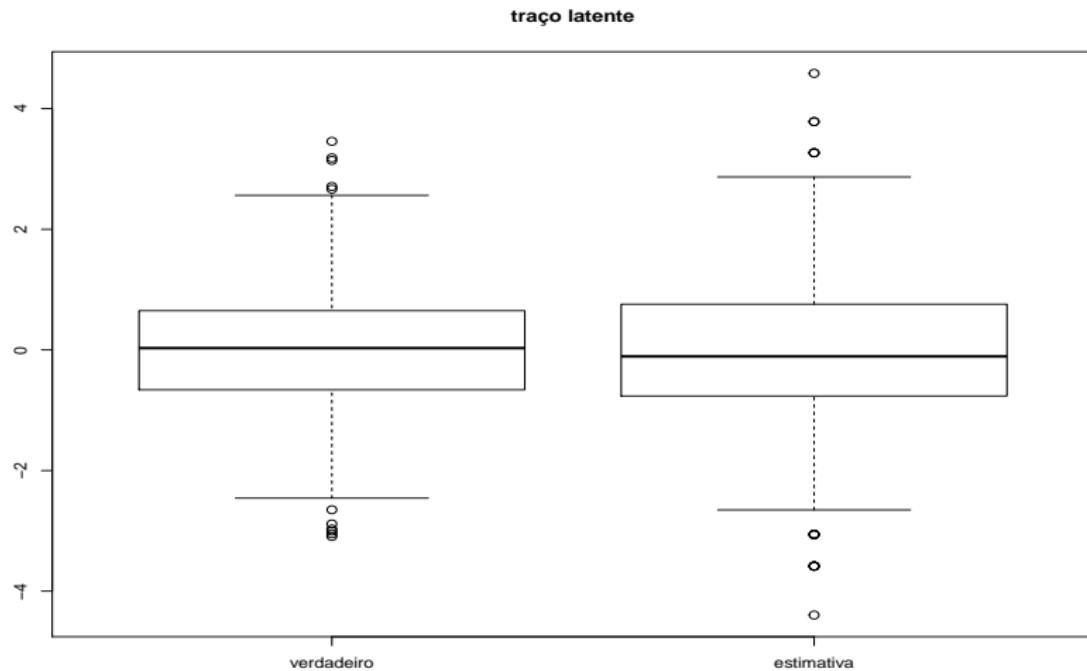
Resultados da estimação dos traços latentes



Resultados da estimativa dos traços latentes



Resultados da estimativa dos traços latentes



Invariância na estimação das habilidades

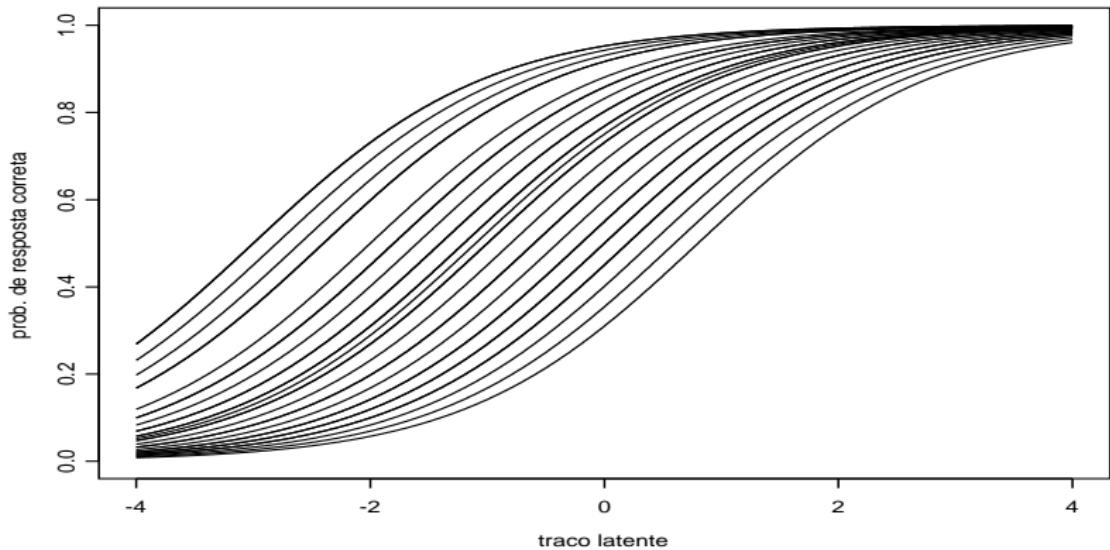
- As estimativas obtidas através da TRI possuem a propriedade da invariância, ou seja, uma vez obtidos os seus valores, estes são únicos.
- Considere a estimação das habilidades dos mesmos indivíduos obtidas a través de dois outros conjuntos de itens (provas).
- O primeiro conjunto é constituído de itens,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

Descrição dos itens do teste 2

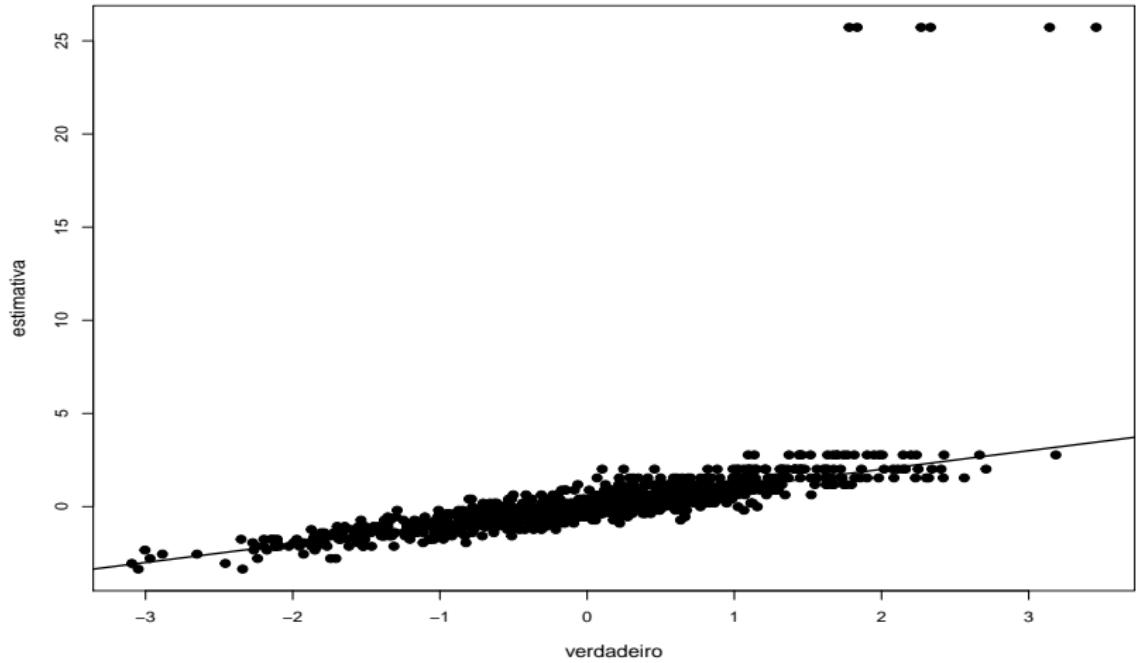
Item	Dificuldade (b)	Item	Dificuldade (b)	Item	Dificuldade (b)
1	-3,0	1	-0,6	1	-2,4
2	-2,8	2	-0,4	2	-1,8
3	-2,4	3	-0,2	3	-1,4
4	-2,0	4	0,0	4	-1,0
5	-1,8	5	0,2	5	-0,6
6	-1,6	6	0,4	6	-0,2
7	-1,4	7	0,6	7	0,2
8	-1,2	8	0,8	8	-2,6
9	-1,0	9	-1,1	9	-1,2
10	-0,8	10	-3,0	10	0,0

Representação Gráfica dos Itens - teste 2

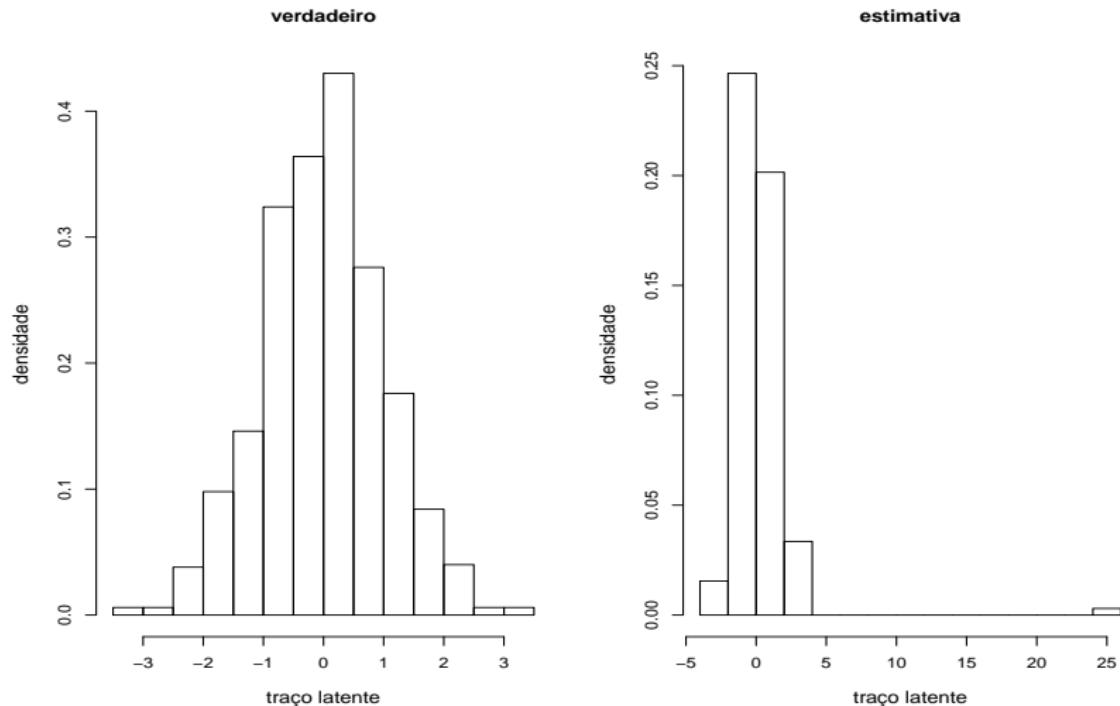
Curvas Características dos 30 itens



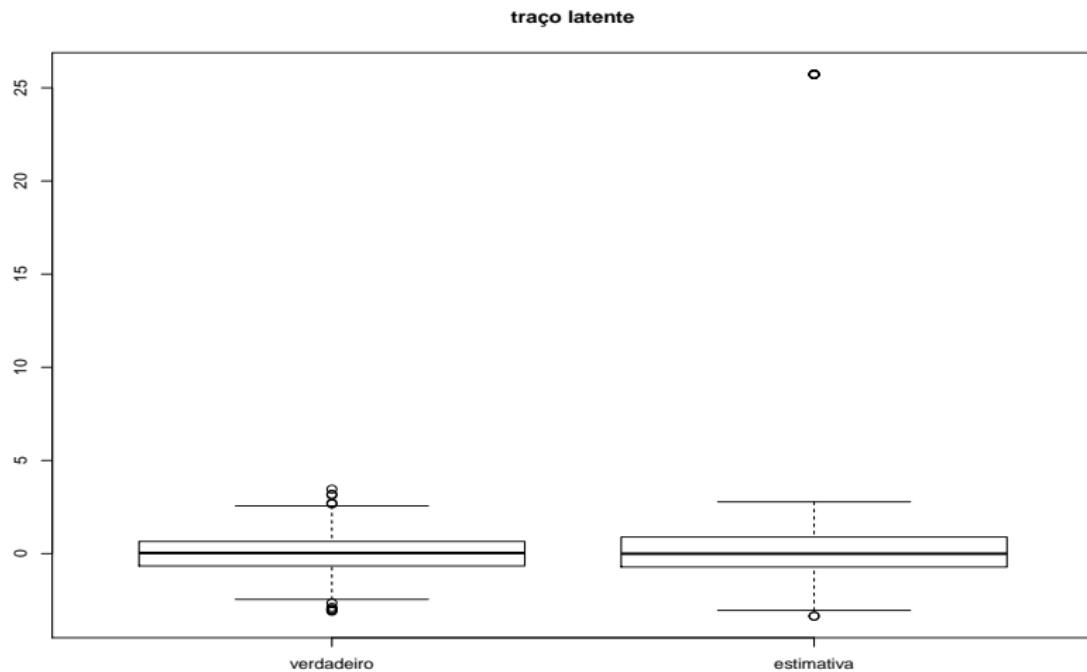
Resultados da estimação dos traços latentes



Resultados da estimativa dos traços latentes



Resultados da estimativa dos traços latentes

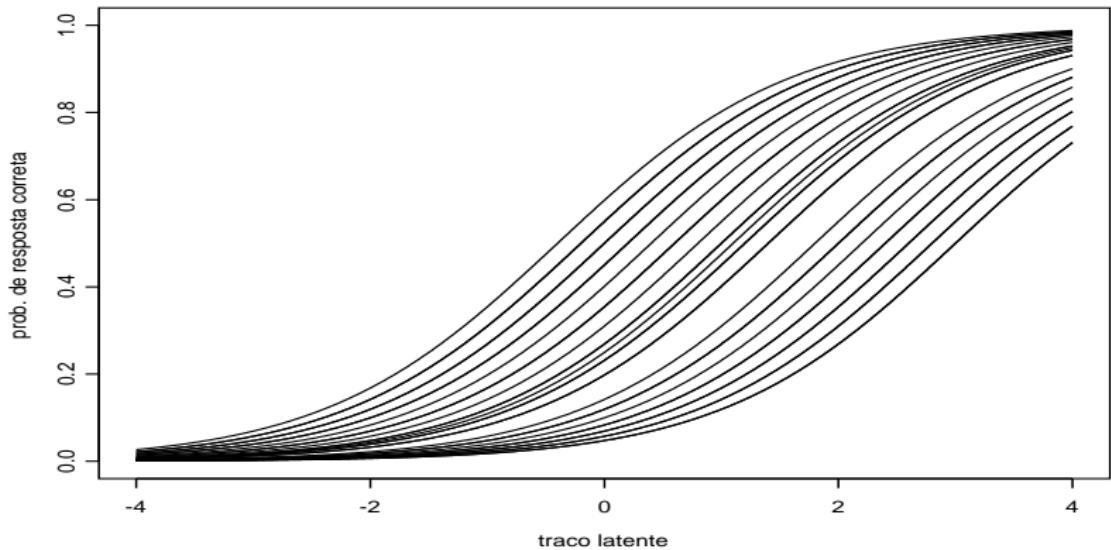


Descrição dos itens do teste 3

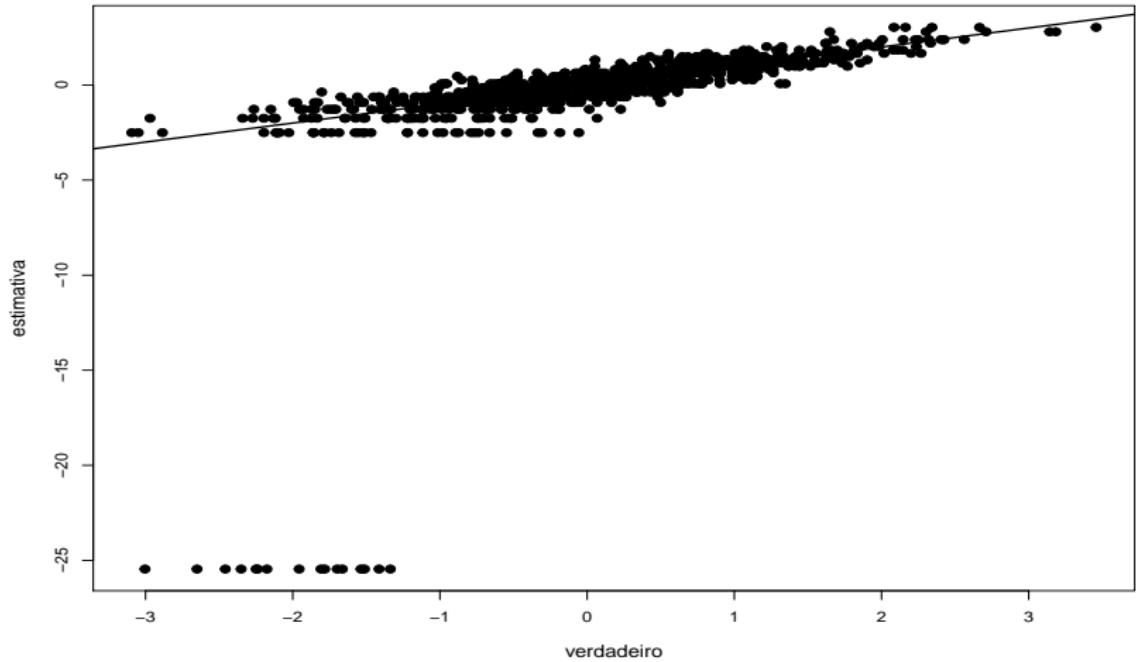
Item	Dificuldade (b)	Item	Dificuldade (b)	Item	Dificuldade (b)
1	1,0	1	1,1	1	0,2
2	1,2	2	1,0	2	0,4
3	1,4	3	1,4	3	0,6
4	1,8	4	2,0	4	0,8
5	2,0	5	2,4	5	0,2
6	2,2	6	2,8	6	0,6
7	2,4	7	3,0	7	0,0
8	2,6	8	2,6	8	-0,2
9	2,8	9	1,2	9	-0,2
10	3,0	10	0,0	10	-0,4

Representação Gráfica dos Itens - teste 3

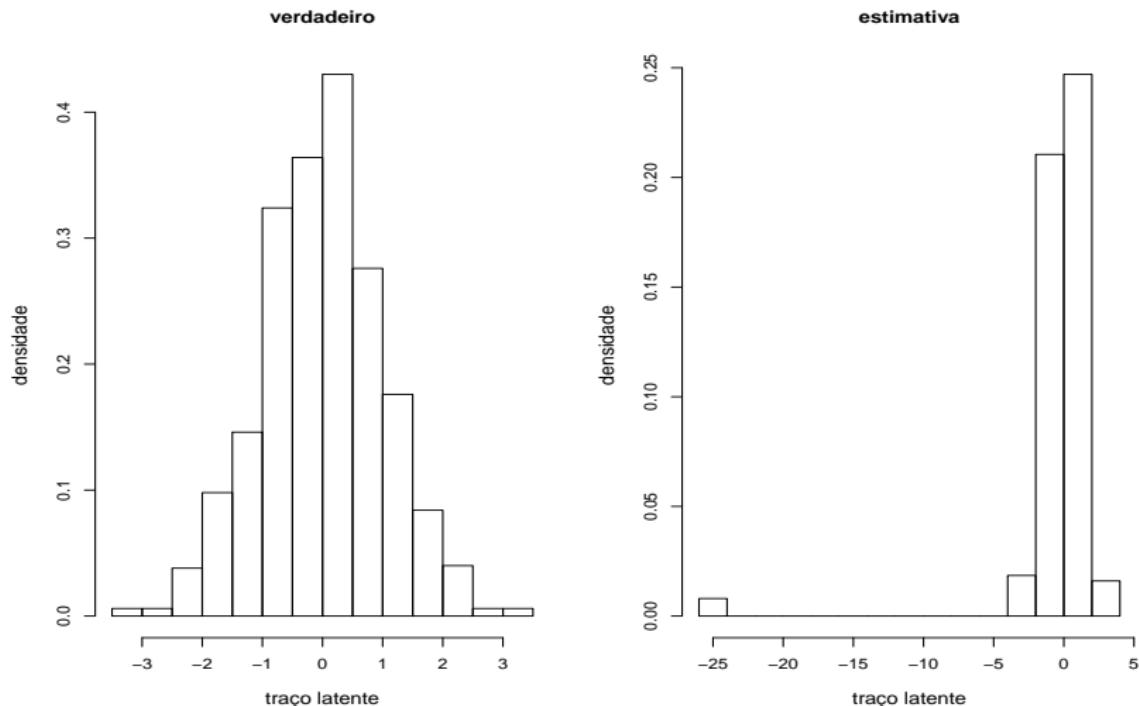
Curvas Características dos 30 itens



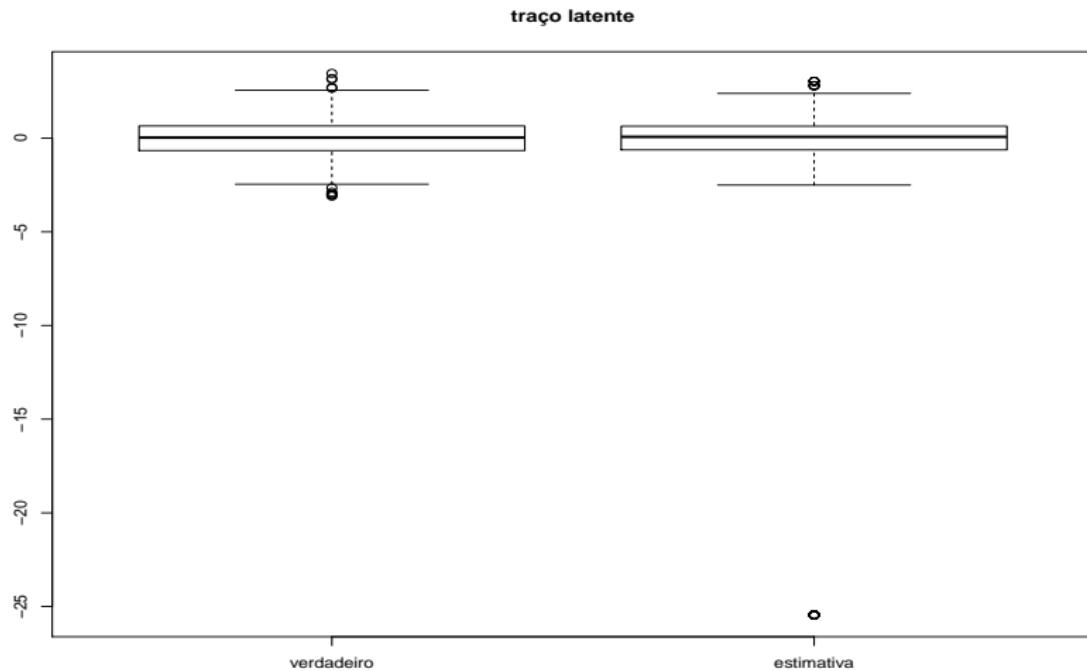
Resultados da estimação dos traços latentes



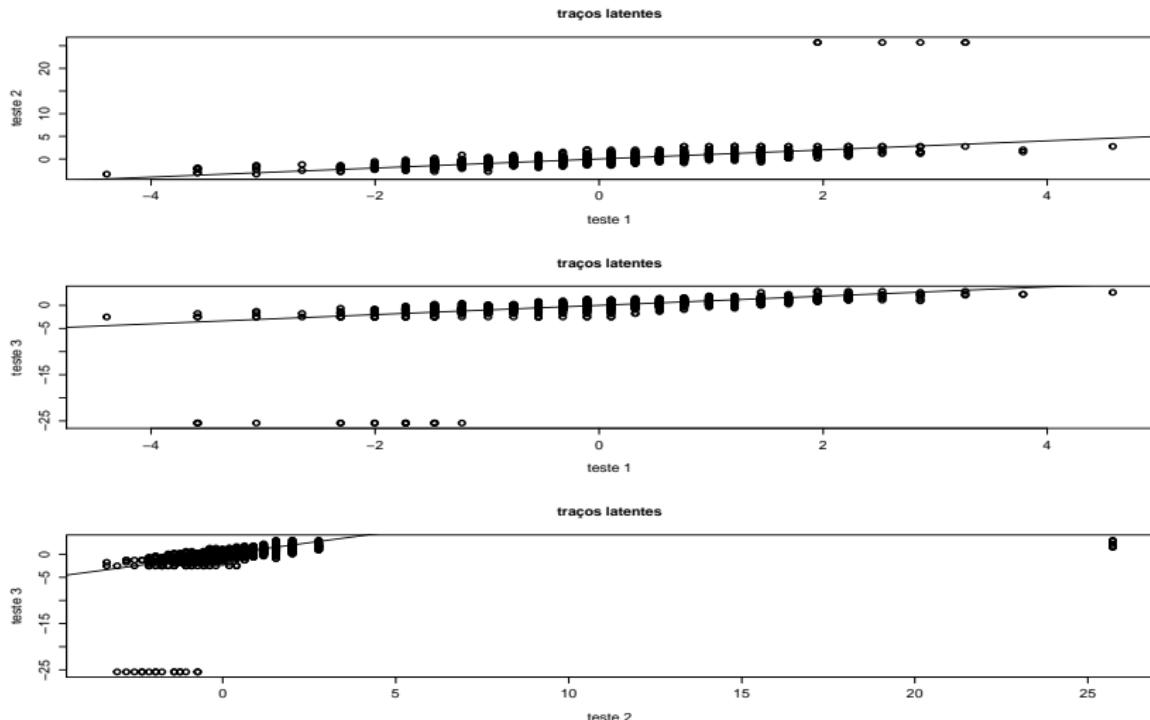
Resultados da estimativa dos traços latentes



Resultados da estimativa dos traços latentes



Resultados da estimativa dos traços latentes



Habilidades conhec. - Parâmetros dos itens desc.

- Logverossimilhança

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

- Equações de estimação

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

Desenvolvimento das equações de estimação

Mas,

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

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.
- 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

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

Escore de Fisher

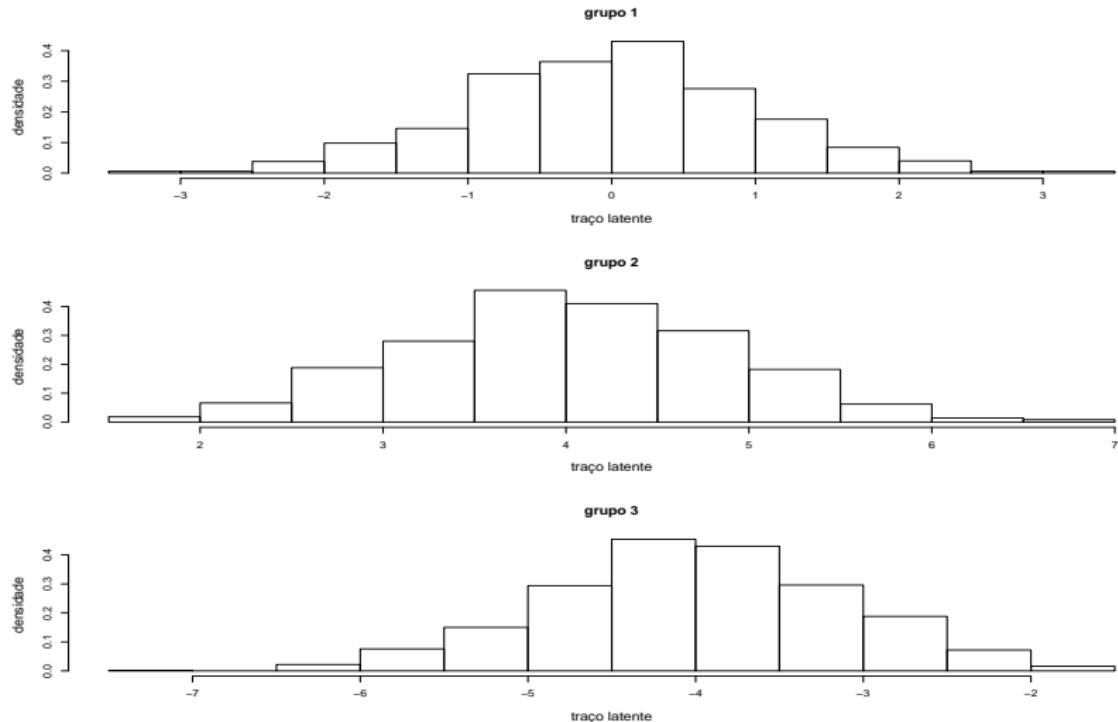
$$\hat{b}_i^{(t+1)} = \hat{b}_i^{(t)} + [I(\hat{b}_i^{(t)})]^{-1} S(\hat{b}_i^{(t)}).$$

- Estimativas iniciais : proporção de erros padronizadas. Erros-padrão: inversa da informação de Fisher.

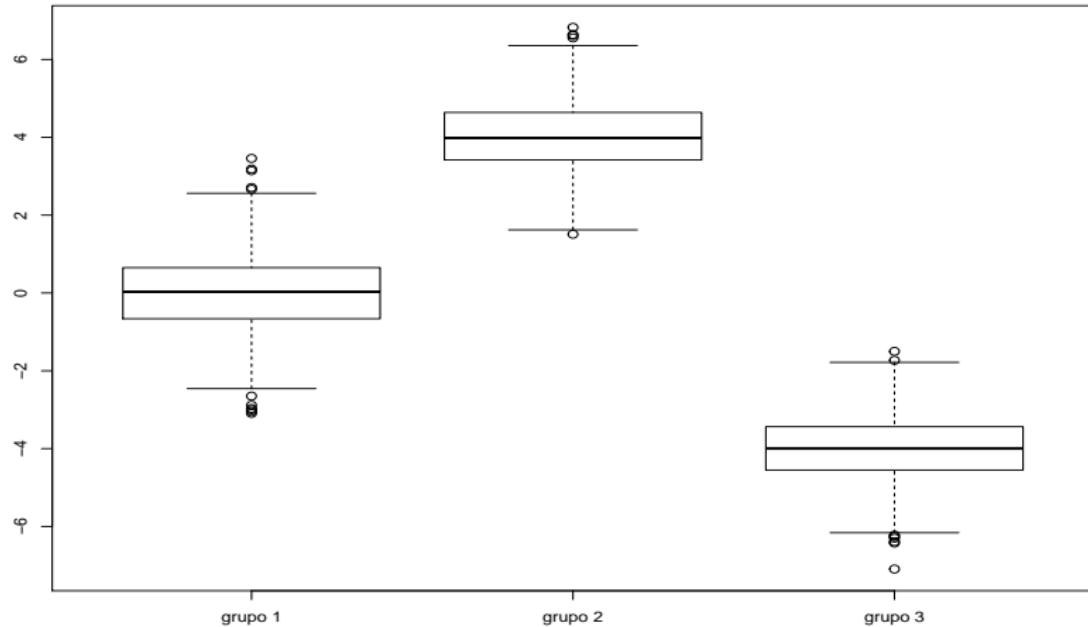
Usando o Teste 1 e 3 grupos de indivíduos

- Considere três grupos de $n=1000$ indivíduos, com as proficiências conhecidas, submetidos a uma prova com $I = 30$ itens (com os parâmetros desconhecidos).
- Foram simulados a partir de distribuições normais diferentes (veja os códigos).

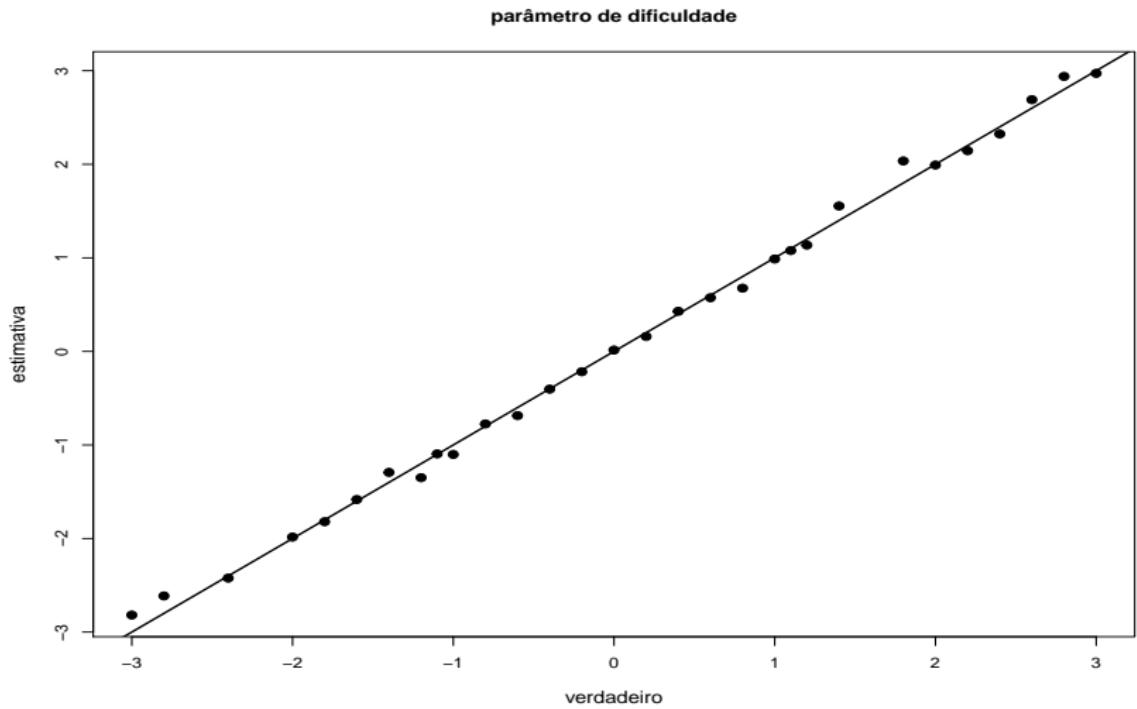
Histogramas dos traços latentes



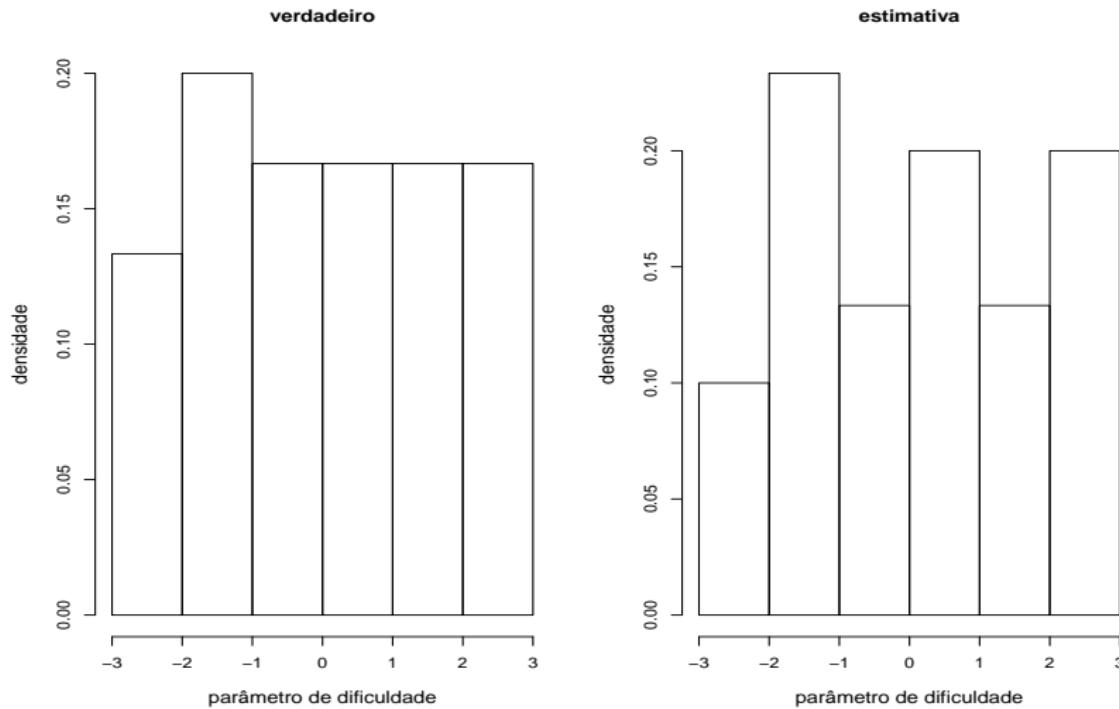
Boxplots dos traços latentes



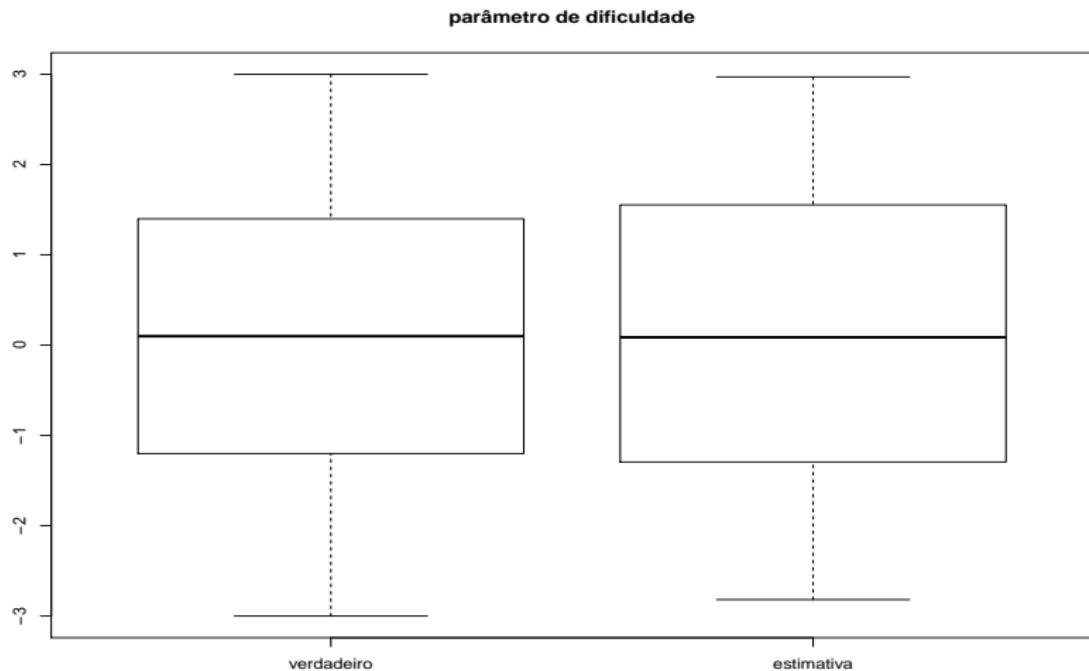
Resultados da estimativa dos parâmetros dos itens - G1



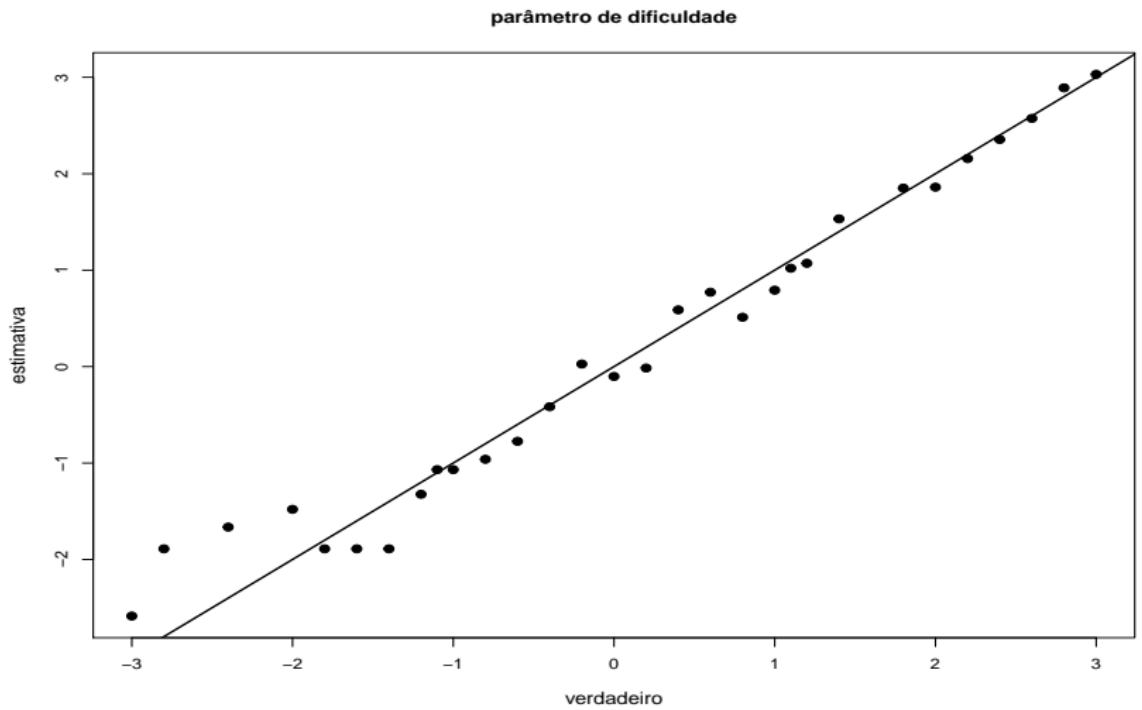
Resultados da estimativa dos parâmetros dos itens - G1



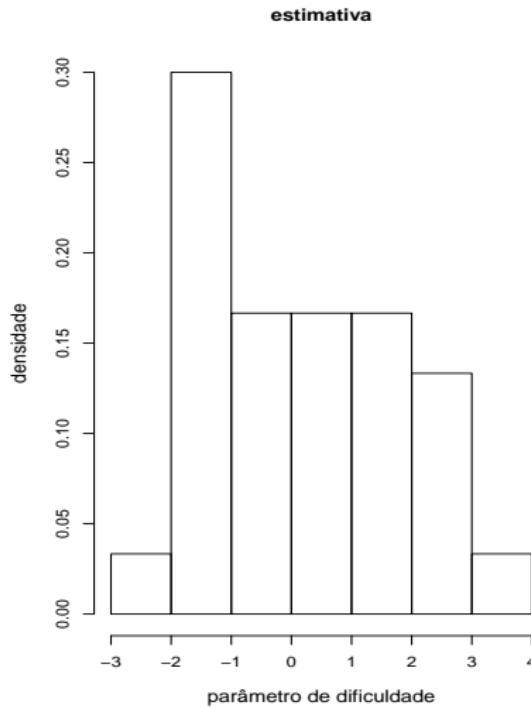
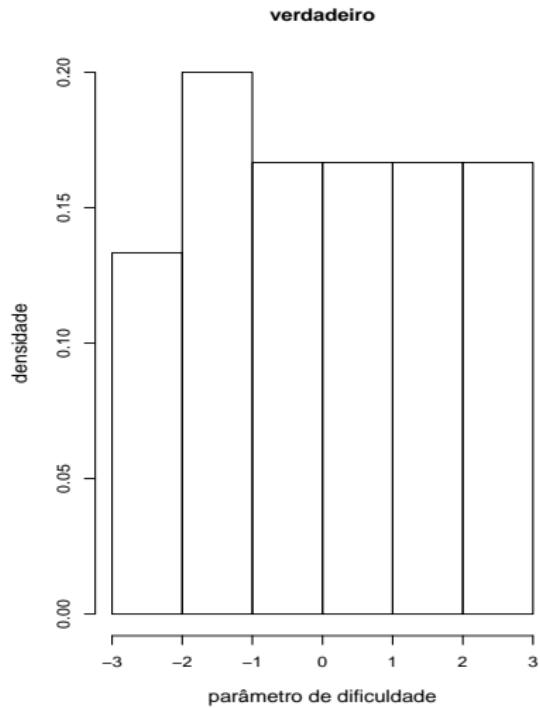
Resultados da estimativa dos parâmetros dos itens - G1



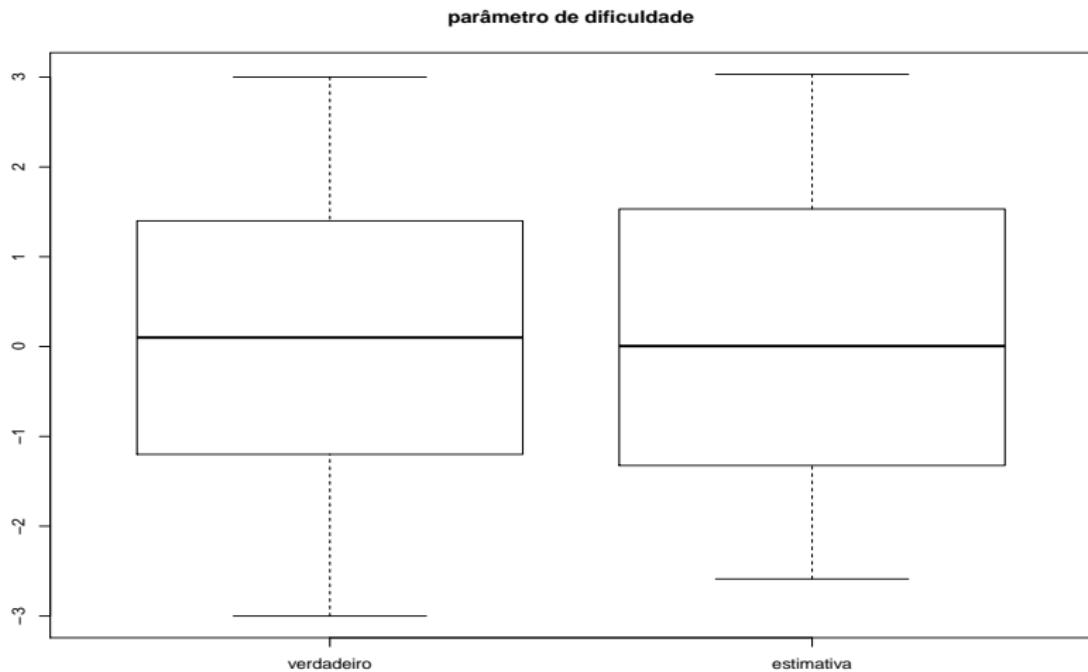
Resultados da estimativa dos parâmetros dos itens - G2



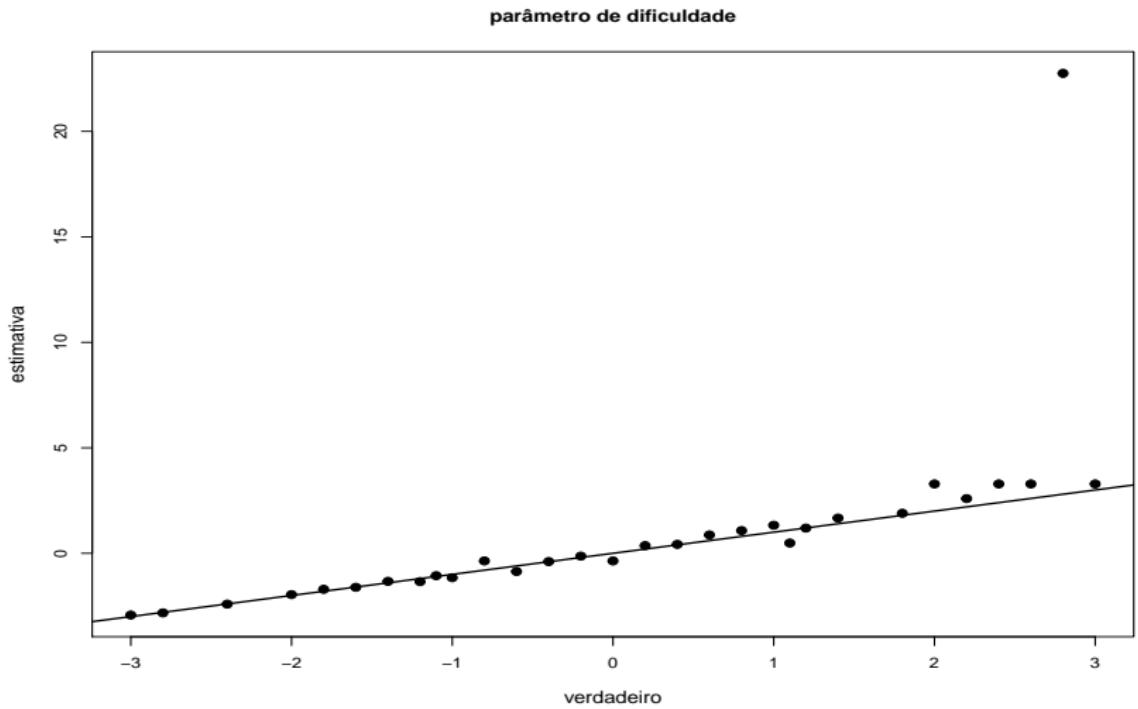
Resultados da estimativa dos parâmetros dos itens - G2



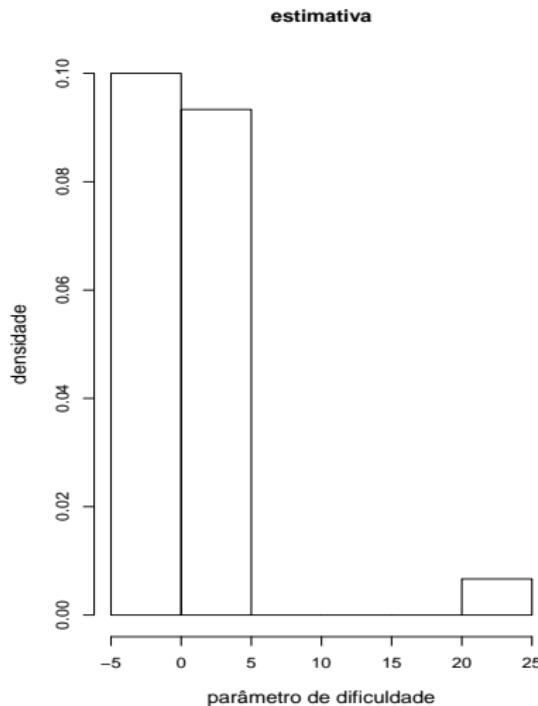
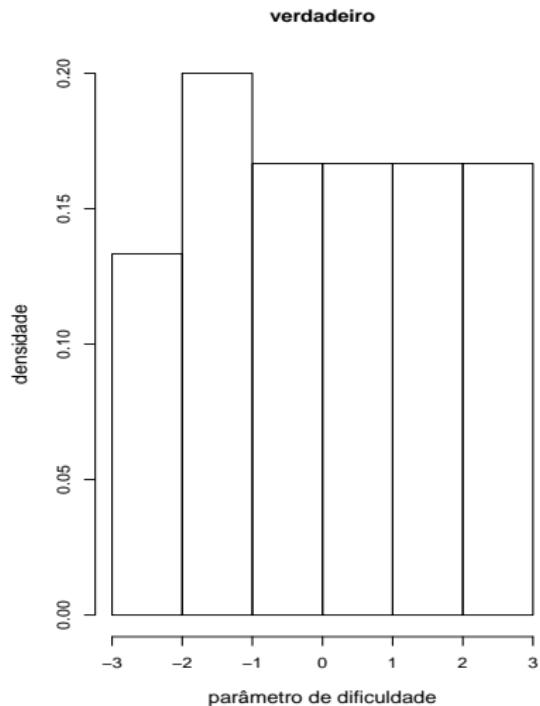
Resultados da estimativa dos parâmetros dos itens - G2



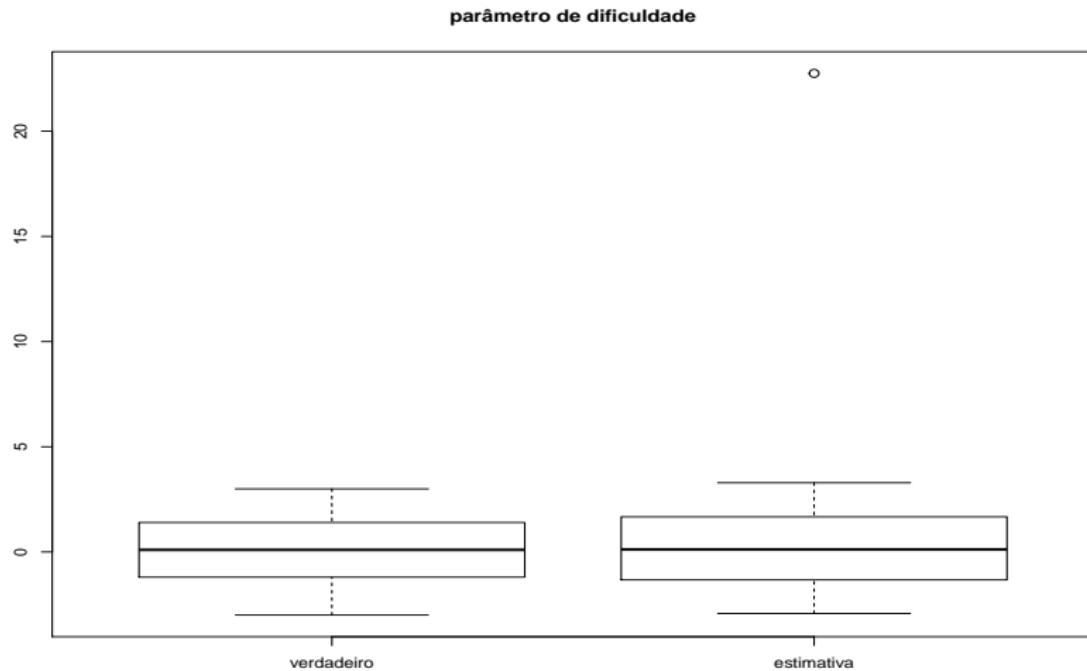
Resultados da estimação dos parâmetros dos itens - G3



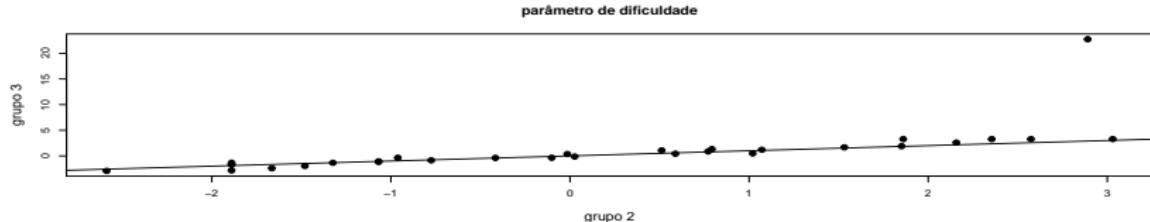
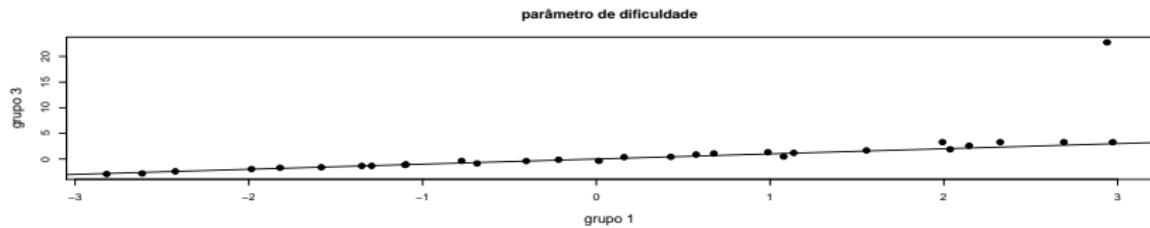
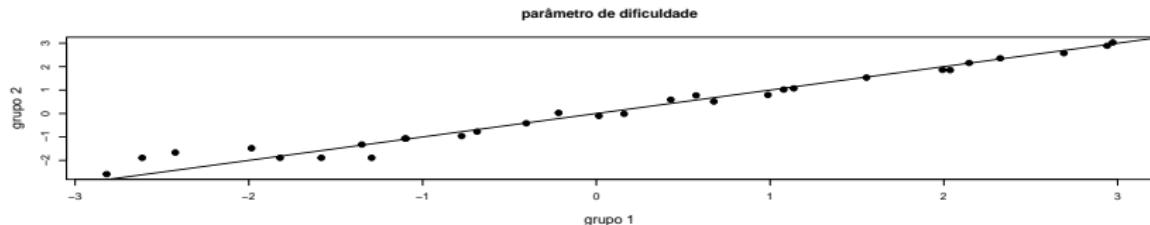
Resultados da estimativa dos parâmetros dos itens - G3



Resultados da estimativa dos parâmetros dos itens - G3



Dispersão entre as estimativas dos parâmetros de dific.



Comentários

- Os erros-padrão assintóticos podem ser calculados estamos através de $I(\hat{b}_i)^{-1}$ e $I(\hat{\theta}_j)^{-1}$.
- Problemas com padrões de resposta escore nulo e escore perfeito (item e indivíduo).
- Pode-se obter estimativas enviesadas para os traços latentes, via MV quando a métrica de sua distribuição se afasta de (0,1), veja Azevedo and Andrade (2009).

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 $n \times l$.
 - 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

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

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

Construção da Verossimilhança Marginal

- Verossimilhança marginal

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

Desenvolvimento das expressões

- logverossimilhança

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

- Estimadores de Máxima verossimilhança (Marginal)

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

Desenvolvimento das expressões

■ Mas,

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

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,

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

portanto,

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

em que,

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

Desenvolvimento das expressões

- Forma de quadratura

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

- Equação de Bock & Aitkin

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

em que

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

Aplicação de um (pseudo) 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 $L(\mathbf{b}|\mathbf{Y}_{..}, \theta)$ 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 $E[\ln L(\mathbf{b}|\mathbf{Y}_{..}, \theta)|\mathbf{Y}_{..}, \hat{\mathbf{b}}^{(t)}]$

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 extraí 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 $\mathbf{r} = (\mathbf{r}_1, \dots, \mathbf{r}_I)'$.

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:

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

- 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 $\bar{\theta} = (\bar{\theta}_1, \dots, \bar{\theta}_q)'$ e π , é

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

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

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

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

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

Desenvolvimento da verossimilhança - Algoritmo EM

- 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{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 r e f obtidos no Passo E, resolver as equações de estimação para ζ_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

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

Erros-padrão: inversa da informação de Fisher. Para outras opções veja o manual do mirt.

Estimação dos traços latentes - Máxima Verossimilhança

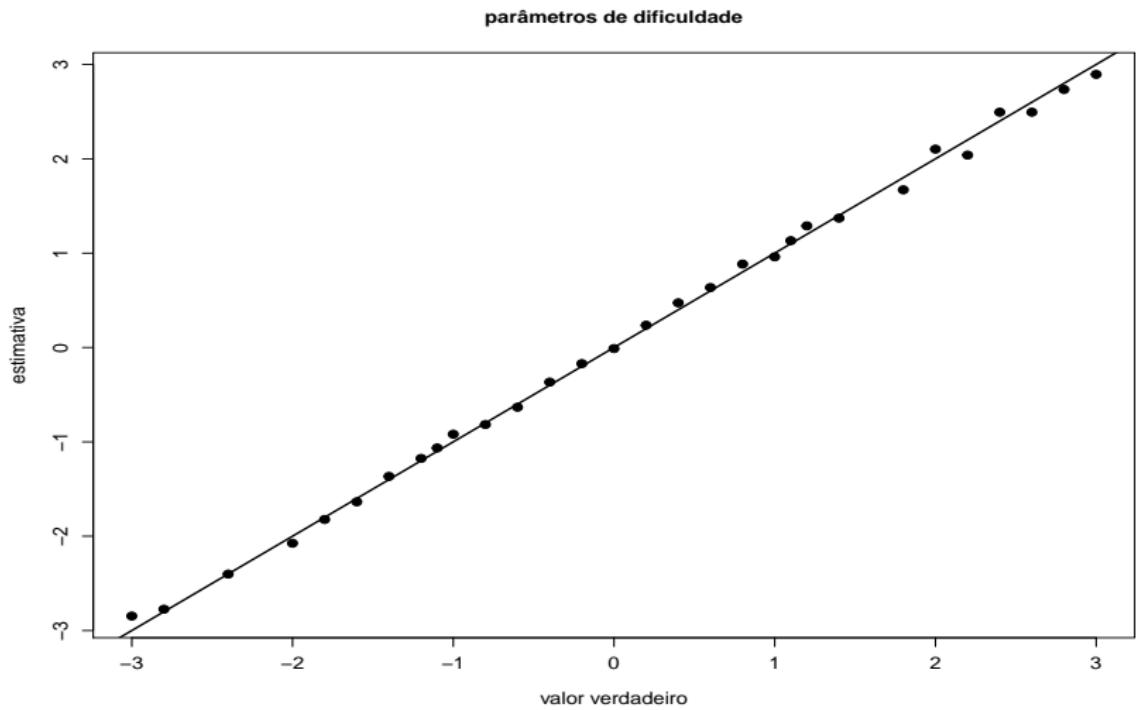
Perfilada

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

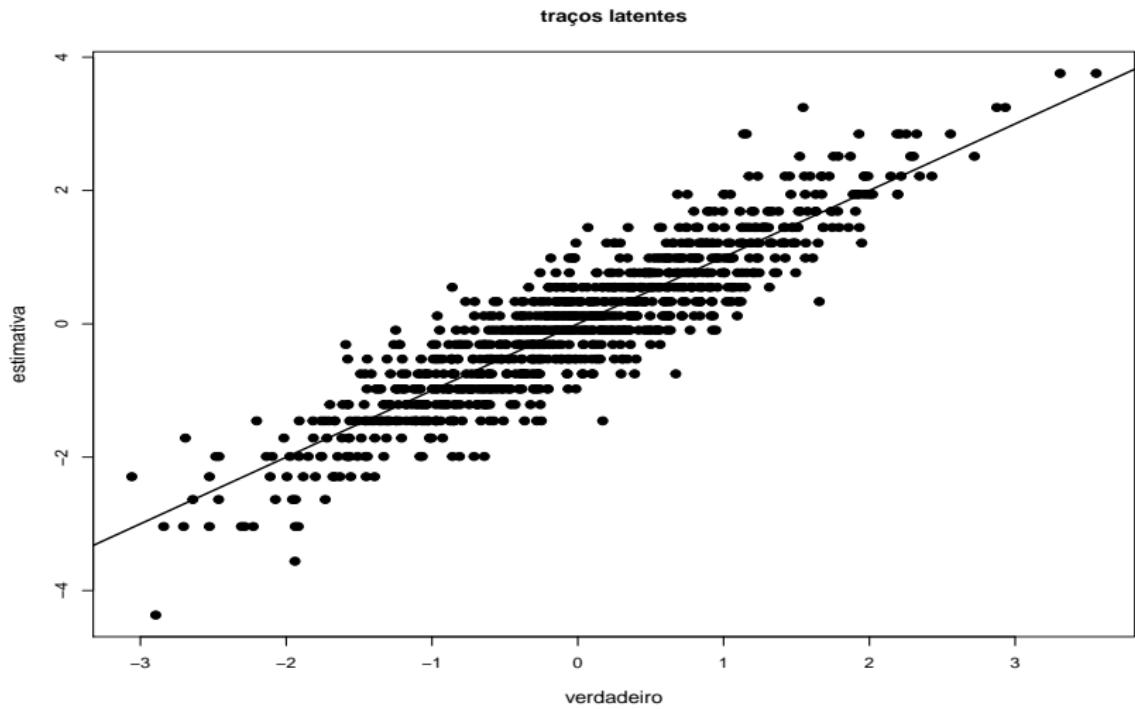
$$L(\theta, \hat{b}) = \prod_{i=1}^I \prod_{j=1}^n \hat{P}_{ij}^{y_{ij}} \hat{Q}_{ij}^{1-y_{ij}},$$

- 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.
- Teste 1 e grupo 1. Mais resultados veja o arquivo: "Traco Latente e par itens desconhecidos MI 685 2 S 2017.r"

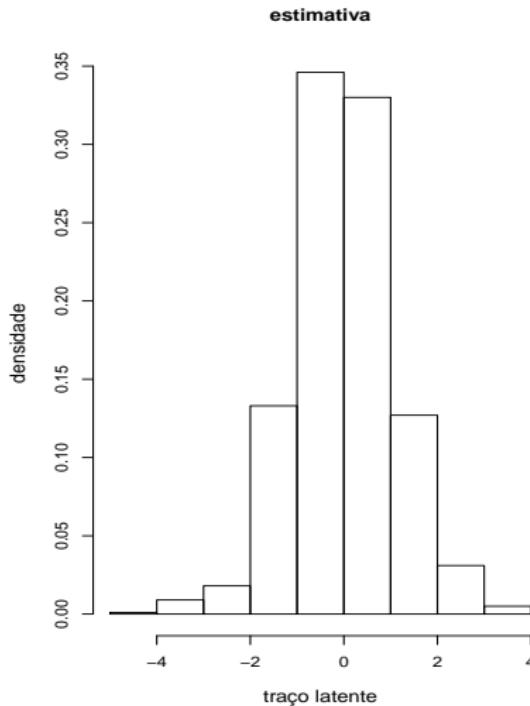
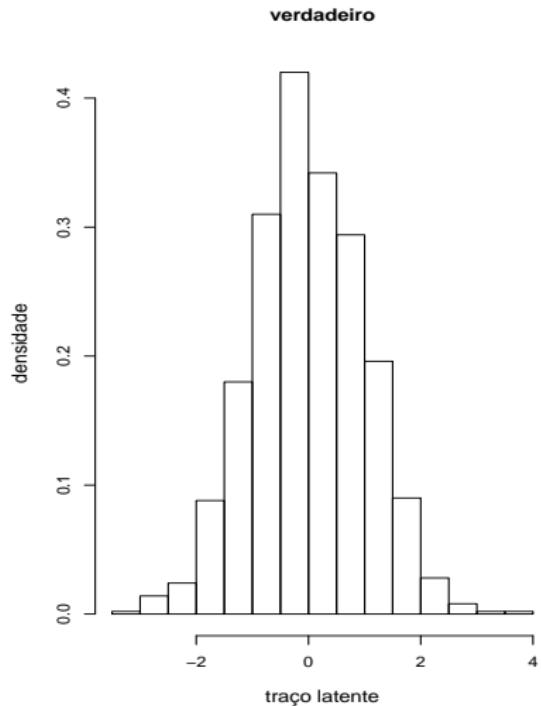
Resultado do processo de estimação



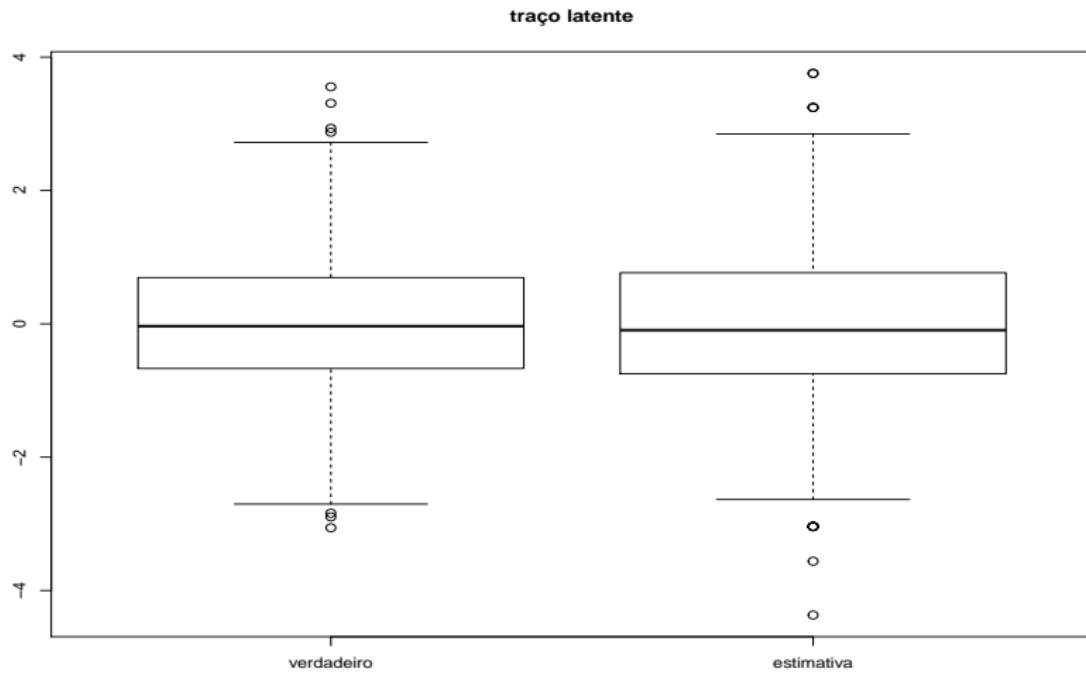
Resultado do processo de estimação



Resultado do processo de estimação



Resultado do processo de estimativa



Modelo de 2 parâmetros

Equações de verossimilhança: Forma de quadratura

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

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

Modelo de 2 parâmetros

Informação de Fisher: Forma de quadratura

$$\begin{aligned} \mathcal{I}(\zeta_i) &= \mathcal{E}\{-\mathbf{H}(\zeta_i)\} \\ &= \sum_{l=1}^q f_{il} P_{il}^* Q_{il}^* \mathbf{h}_{il} \mathbf{h}_{il}', \end{aligned} \tag{2}$$

$$\mathbf{h}_{il} = (P_{il} Q_{il})^{-1} \left(\frac{\partial P_{il}}{\partial \zeta_i} \right) = \begin{pmatrix} \bar{\theta}_l - b_i \\ a_i (1 - c_i) \end{pmatrix} \tag{3}$$

Modelo de 3 parâmetros

Equações de verossimilhança: Forma de quadratura

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

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

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

$$\text{com } W_{ij} = \frac{P_{ij}^* Q_{ij}^*}{P_{ij} Q_{ij}}, \quad P_{ij}^* = \left\{ 1 + e^{-D a_i (\theta_j - b_i)} \right\}^{-1} \text{ e } Q_{ij}^* = 1 - P_{ij}^*$$

Modelo de 3 parâmetros

Informação de Fisher: Forma de quadratura

$$\begin{aligned} \boldsymbol{I}(\zeta_i) &= \mathcal{E}\{-\boldsymbol{H}(\zeta_i)\} \\ &= \sum_{l=1}^q f_{il} P_{il}^* Q_{il}^* \boldsymbol{h}_{il} \boldsymbol{h}_{il}', \end{aligned}$$

em que

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

Comparação de modelos

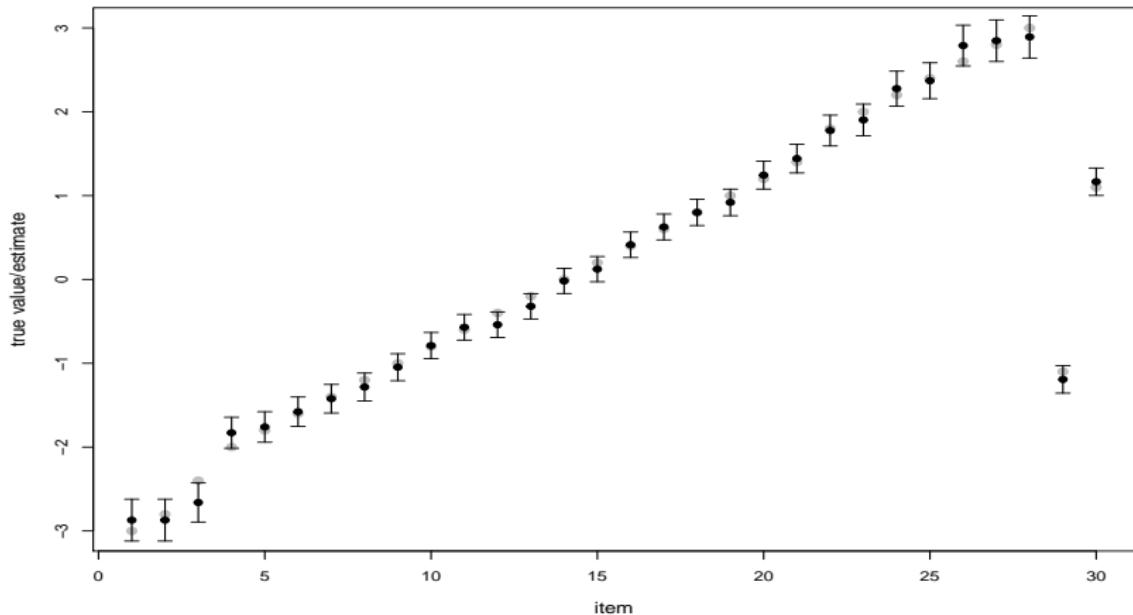
- Seja $I(\zeta, \eta)$ a log-verossimilhança marginal (Equação (1)) e $p = (k_1 + k_2)$ numero de parâmetros, em que k_1 é o número de parâmetros dos itens, k_2 é o número de parâmetros populacionais e n é o número de indivíduos.
- $AIC = -2I(\tilde{\zeta}, \tilde{\eta}) + 2p$.
- $BIC = -2I(\tilde{\zeta}, \tilde{\eta}) + p \ln(n)$.
- $AIC_c = AIC + \frac{2p(p+1)}{n-p-1}$.
- $SABIC = -2I(\tilde{\zeta}, \tilde{\eta}) + p \ln \left(\frac{n+2}{24} \right)$.

Comparação de modelos

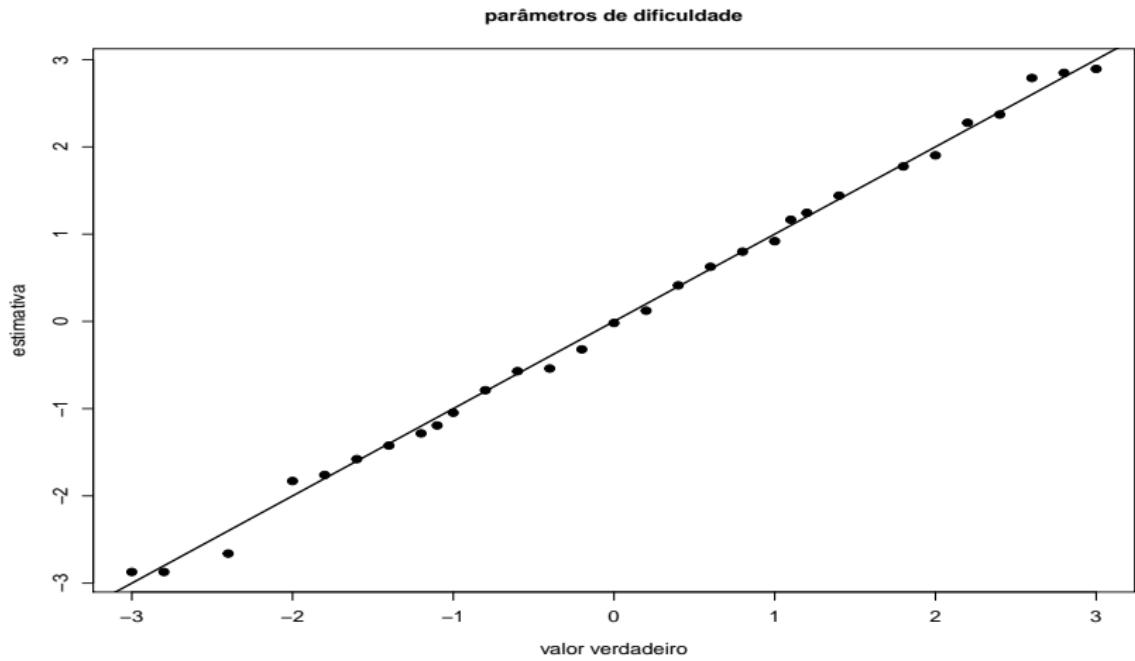
- Os modelos de 2 e 3 parâmetros também foram ajustados.
- Nomenclatura: modelo 1 (1P), modelo 2 (2P), modelo 3 (3P).
- Resultados (AIC/BIC/AICc/SABIC)

modelo	AIC	BIC	AICc	SABIC
1	28567,13	28714,36	28569,05	28619,08
2	28580,42	28874,88	28588,21	28684,32
3	28624,51	29066,21	28642,53	28780,36

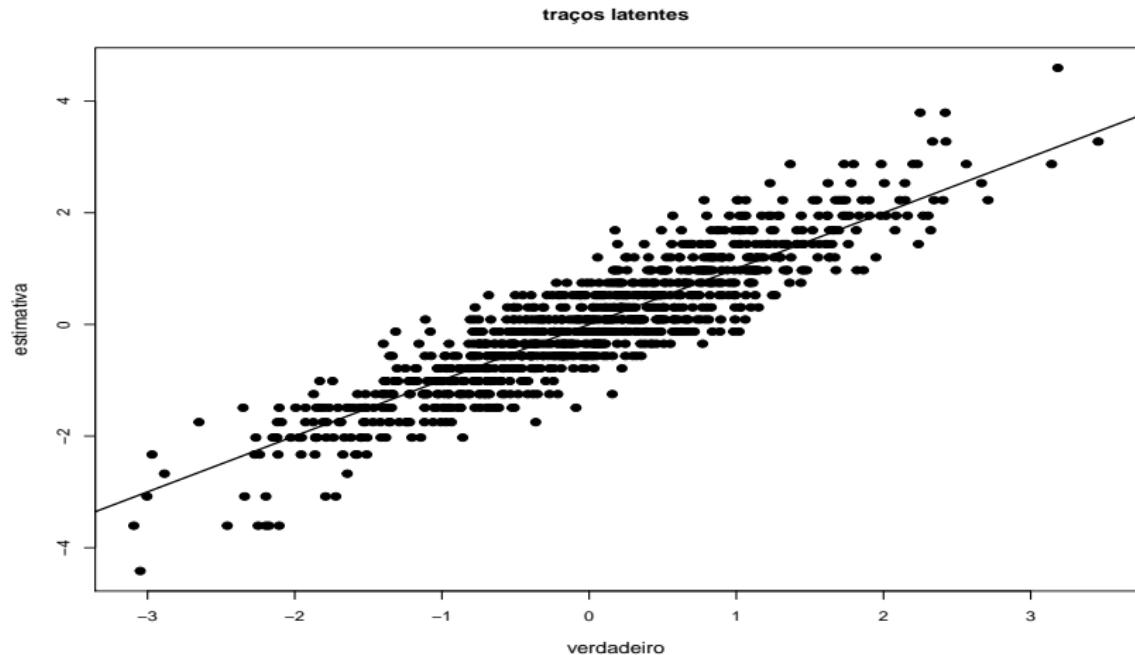
Modelo 1: parâmetro dos itens



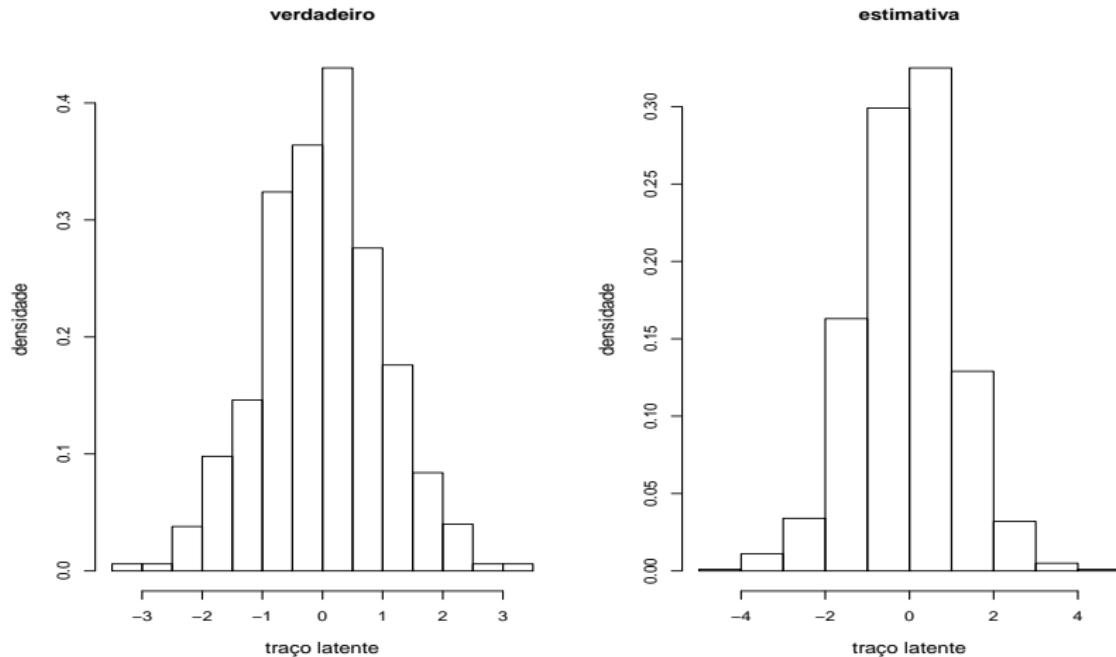
Modelo 1: parâmetro dos itens



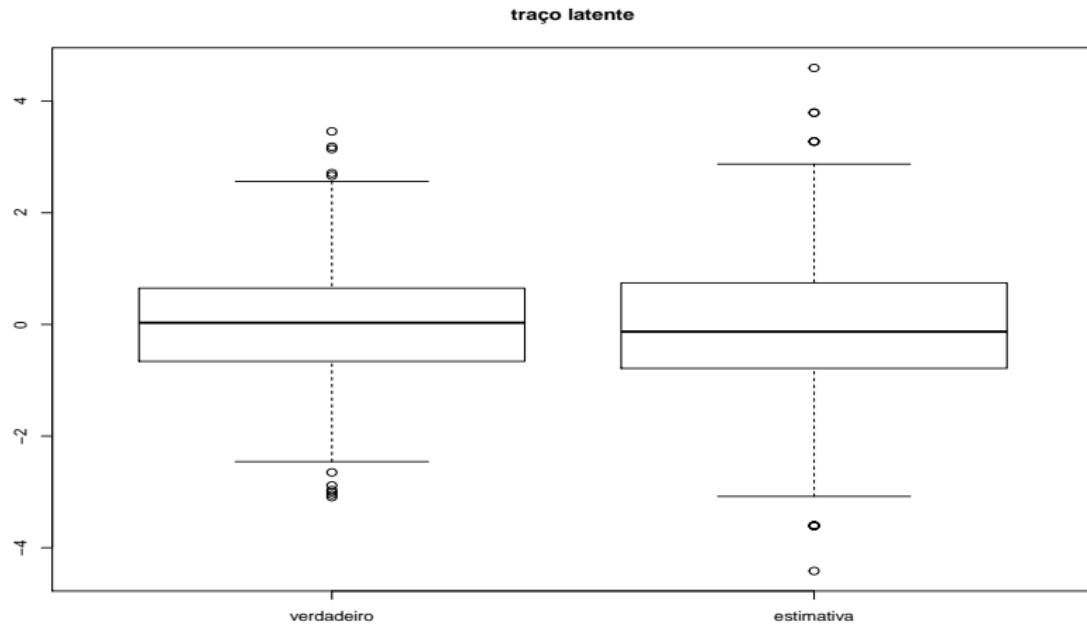
Modelo 1: traços latentes



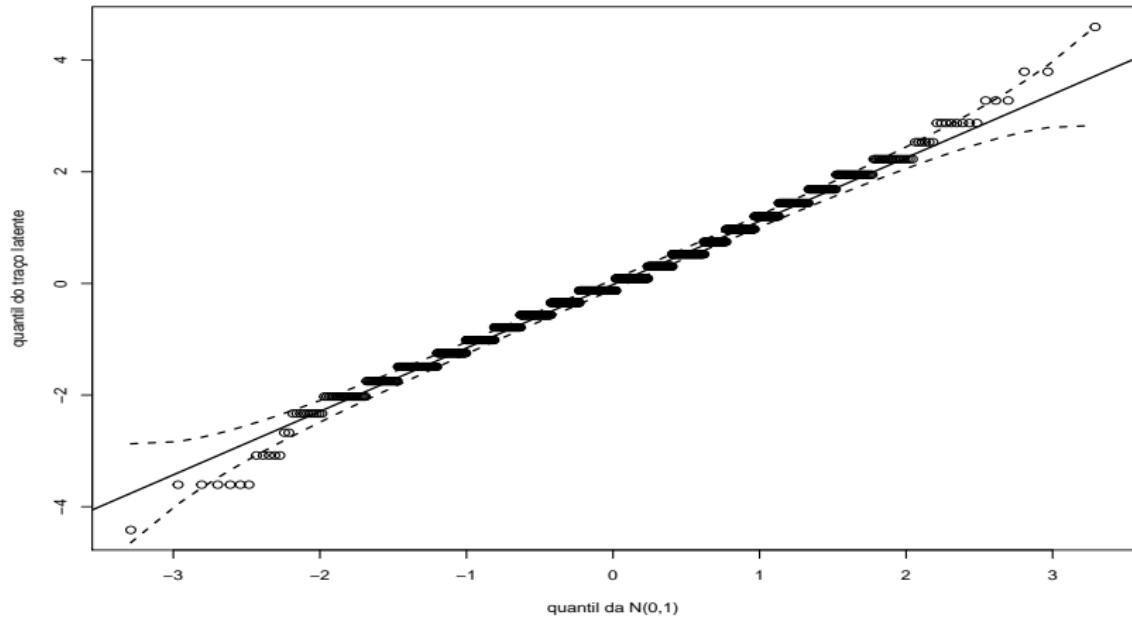
Modelo 1: traços latentes



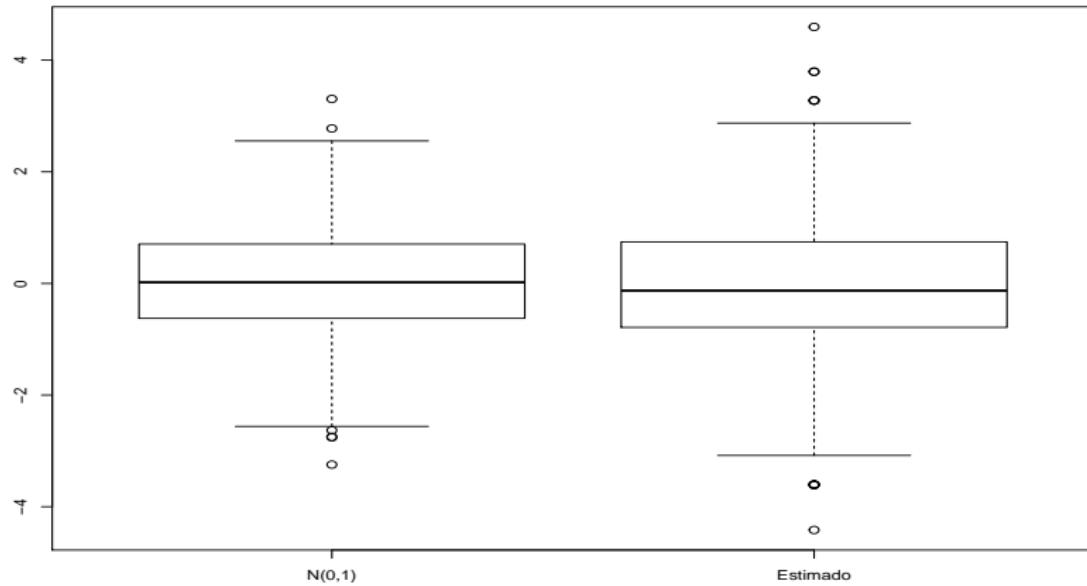
Modelo 1: traços latentes



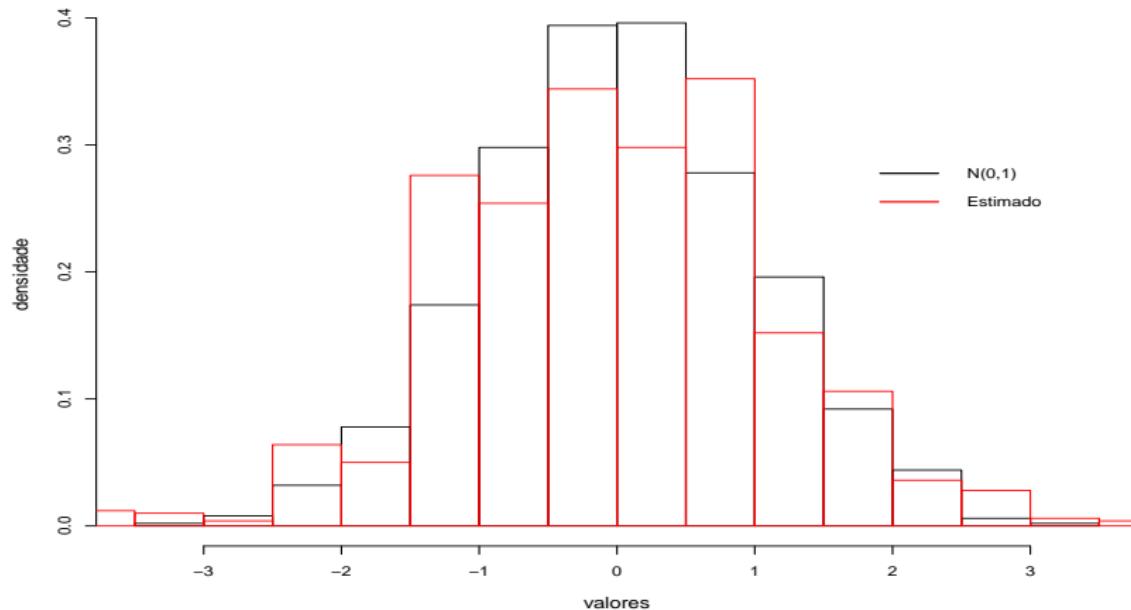
Modelo 1: traços latentes



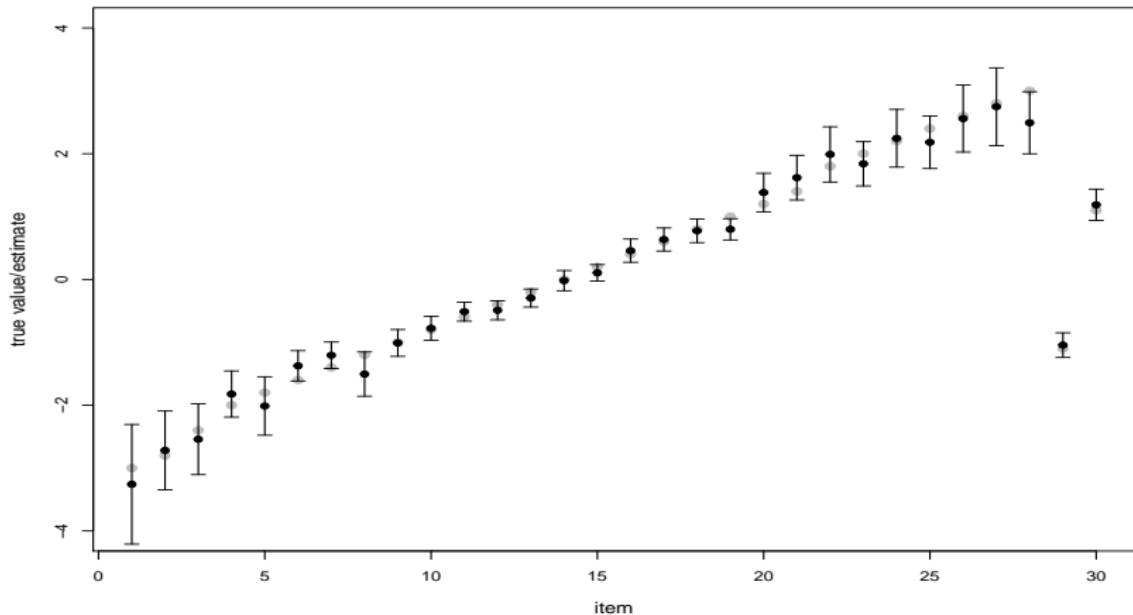
Modelo 1: traços latentes



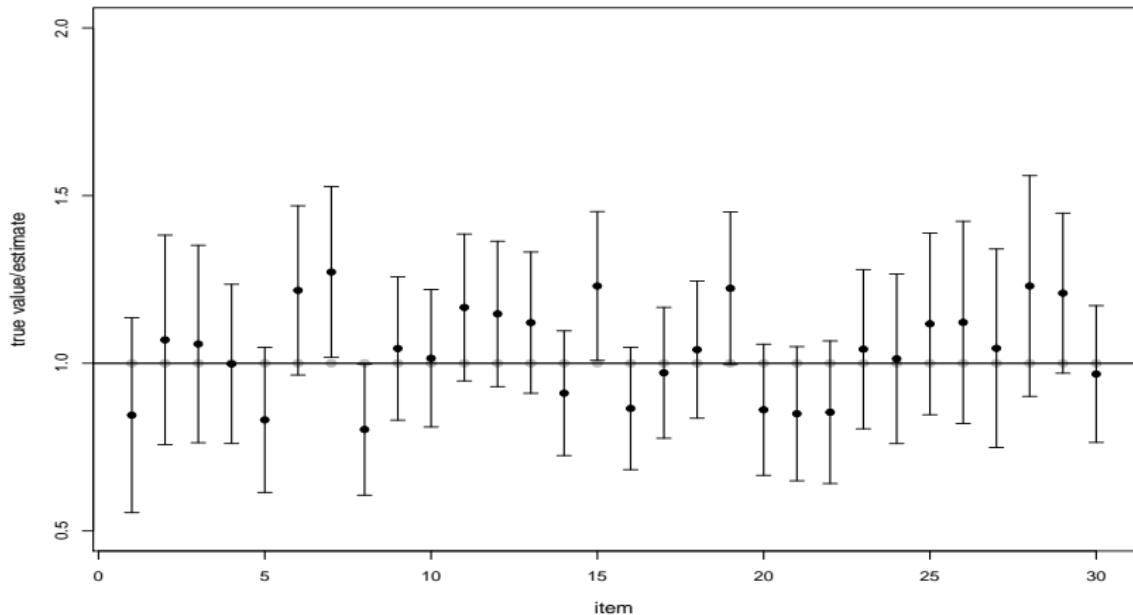
Modelo 1: traços latentes



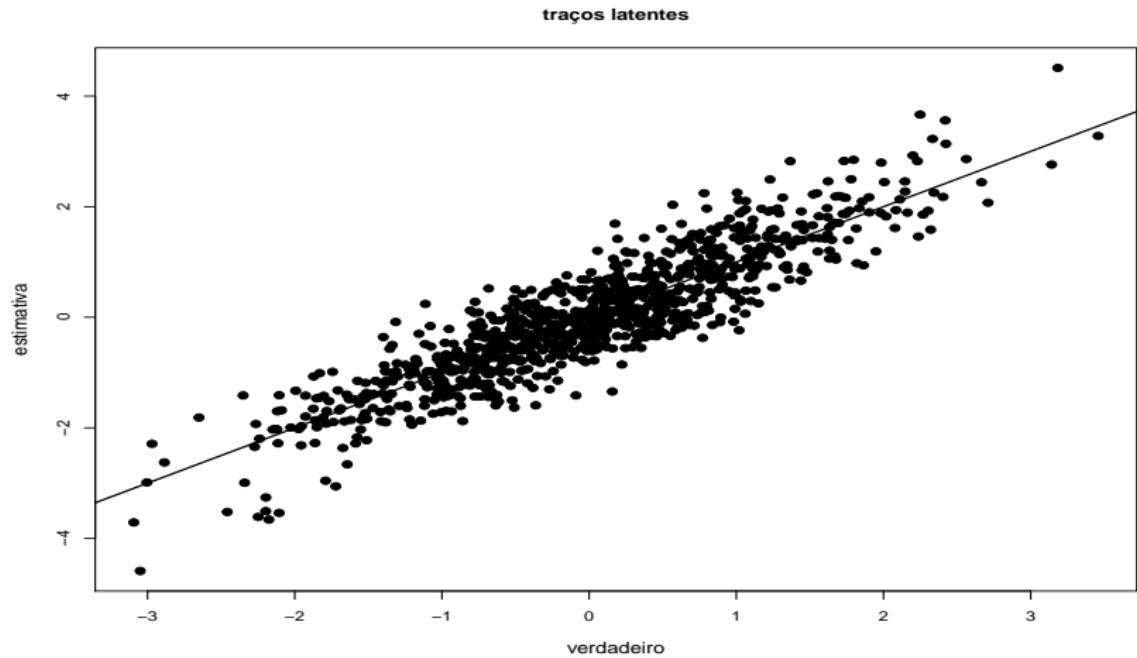
Modelo 2: parâmetro dos itens



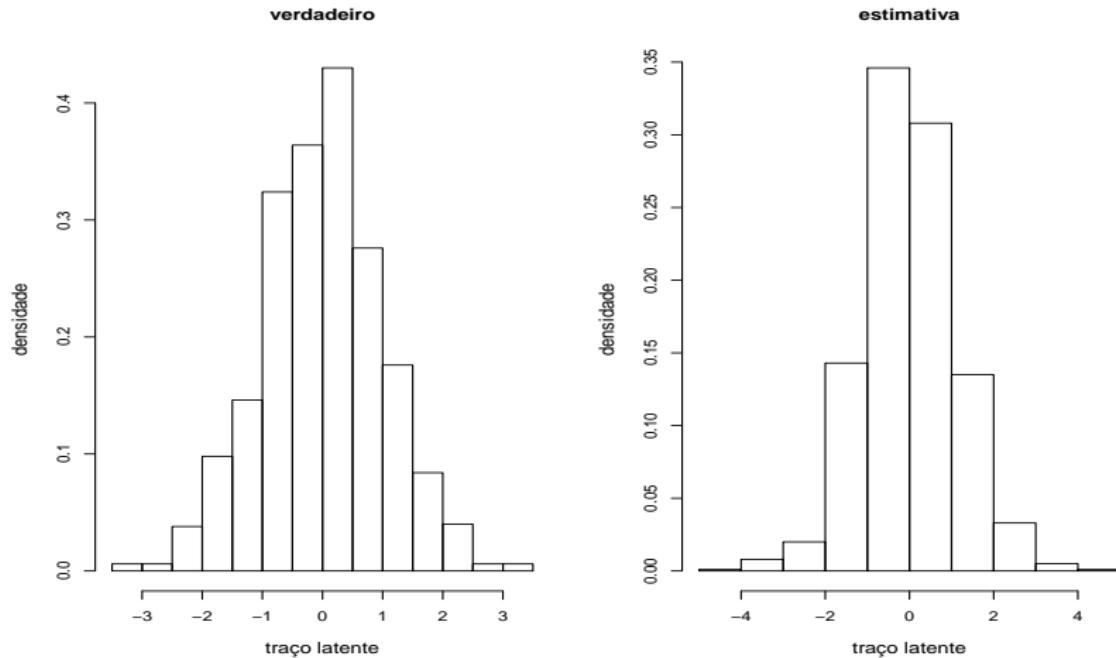
Modelo 2: parâmetro dos itens



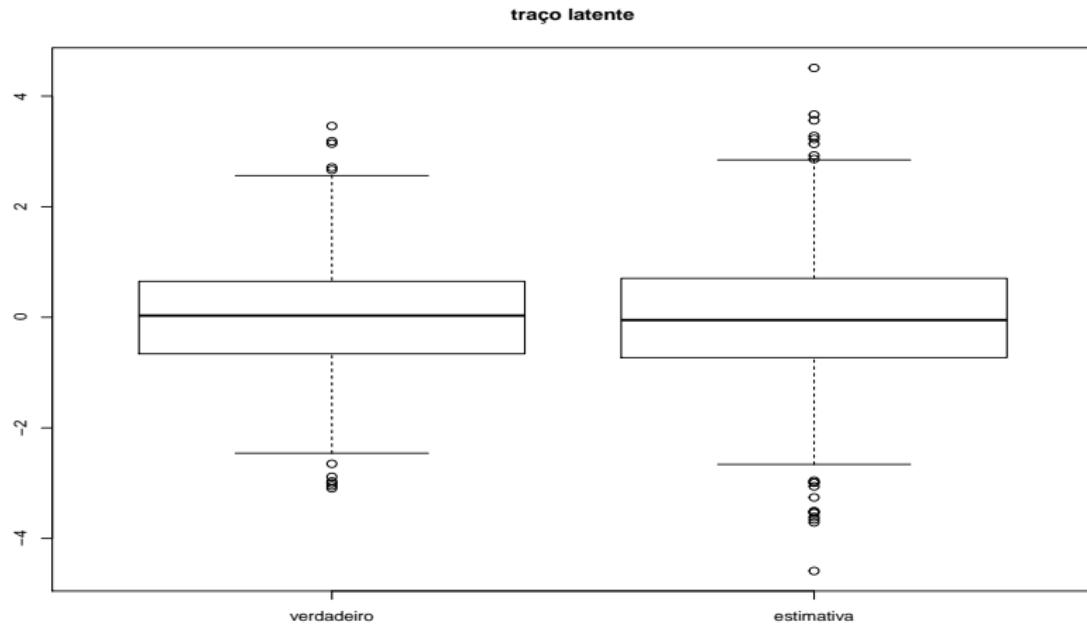
Modelo 2: traços latentes



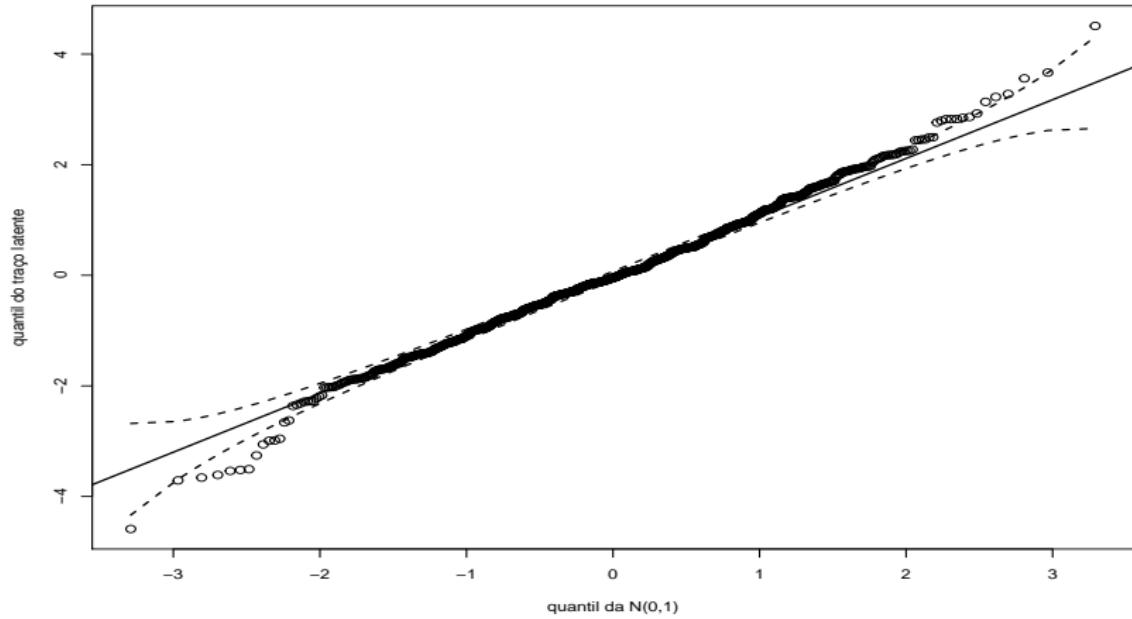
Modelo 2: traços latentes



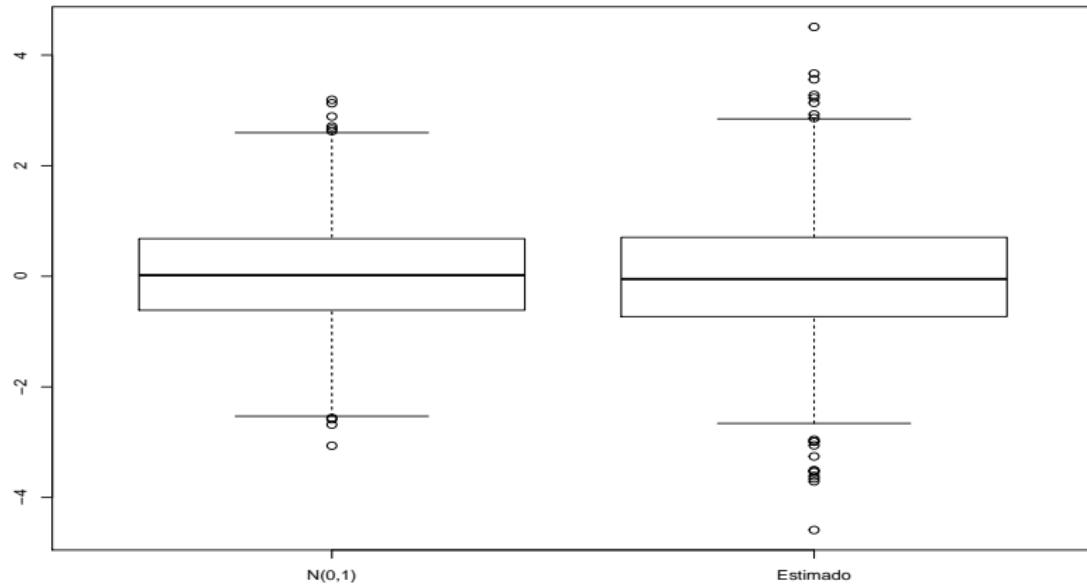
Modelo 2: traços latentes



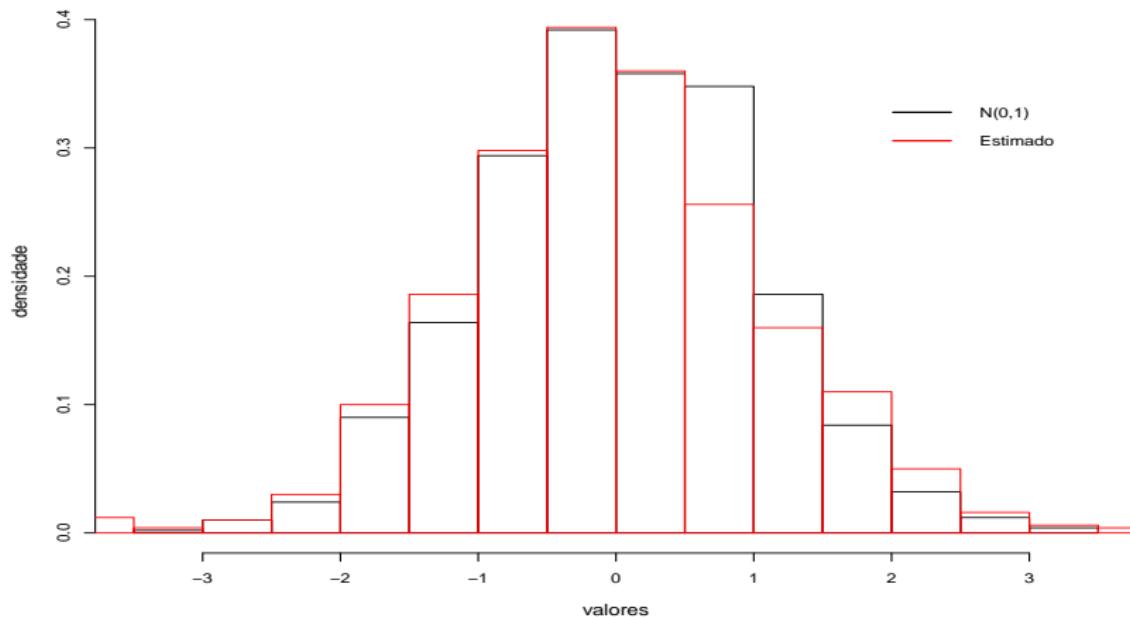
Modelo 2: traços latentes



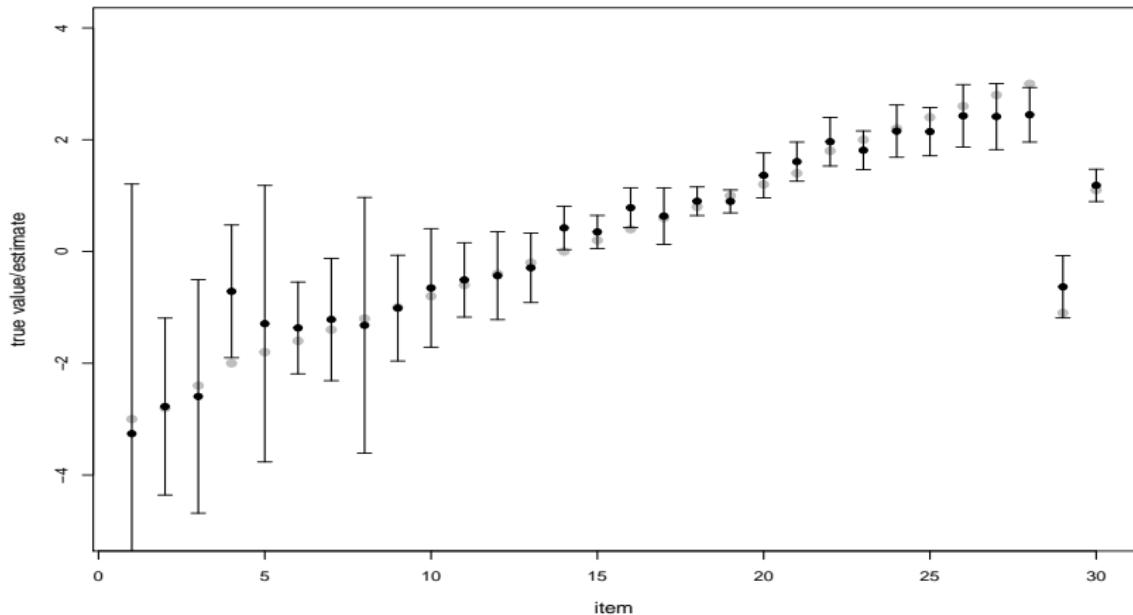
Modelo 2: traços latentes



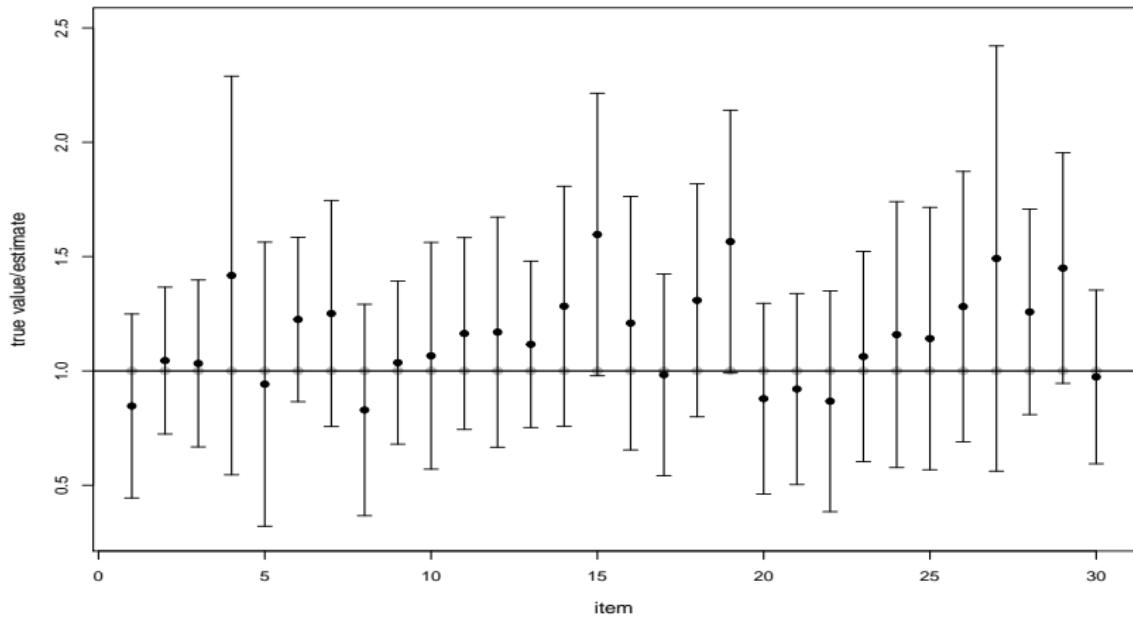
Modelo 2: traços latentes



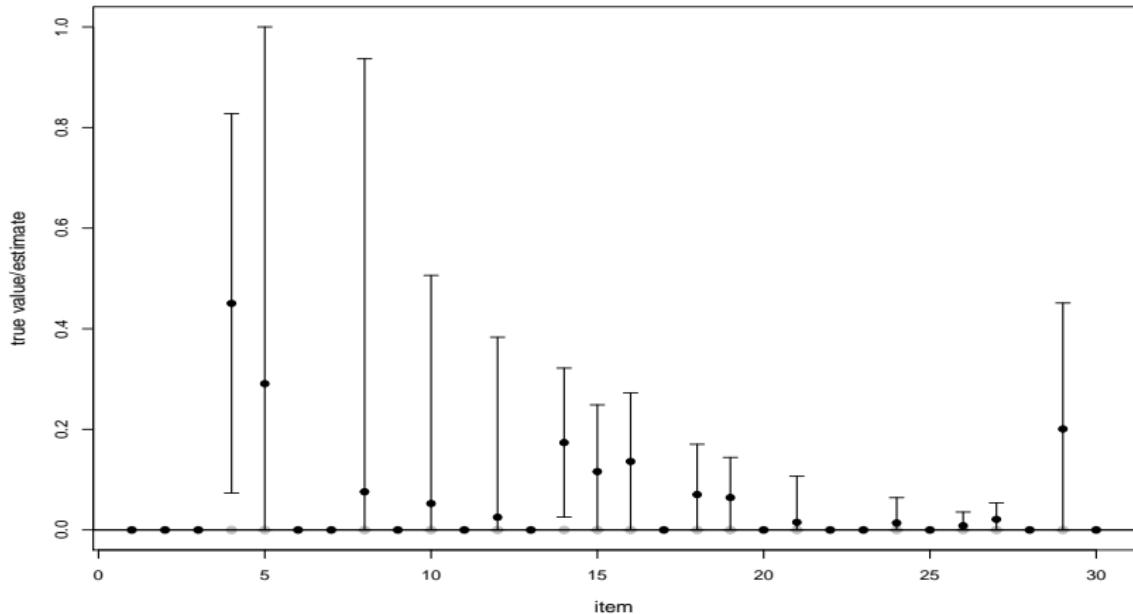
Modelo 3: parâmetro dos itens



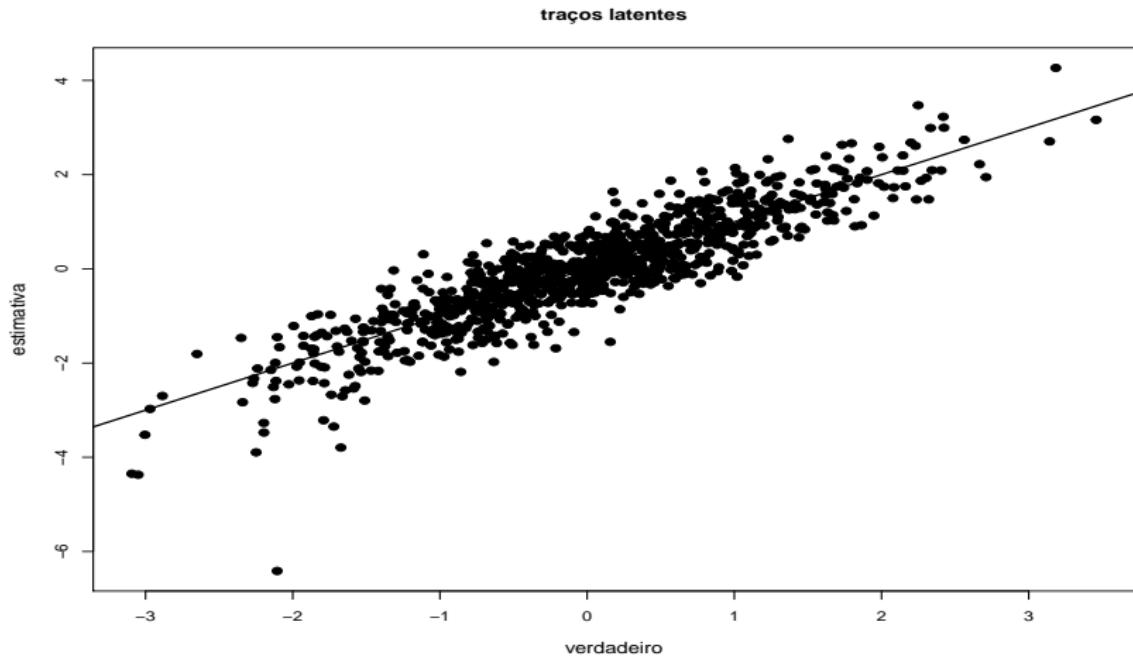
Modelo 3: parâmetro dos itens



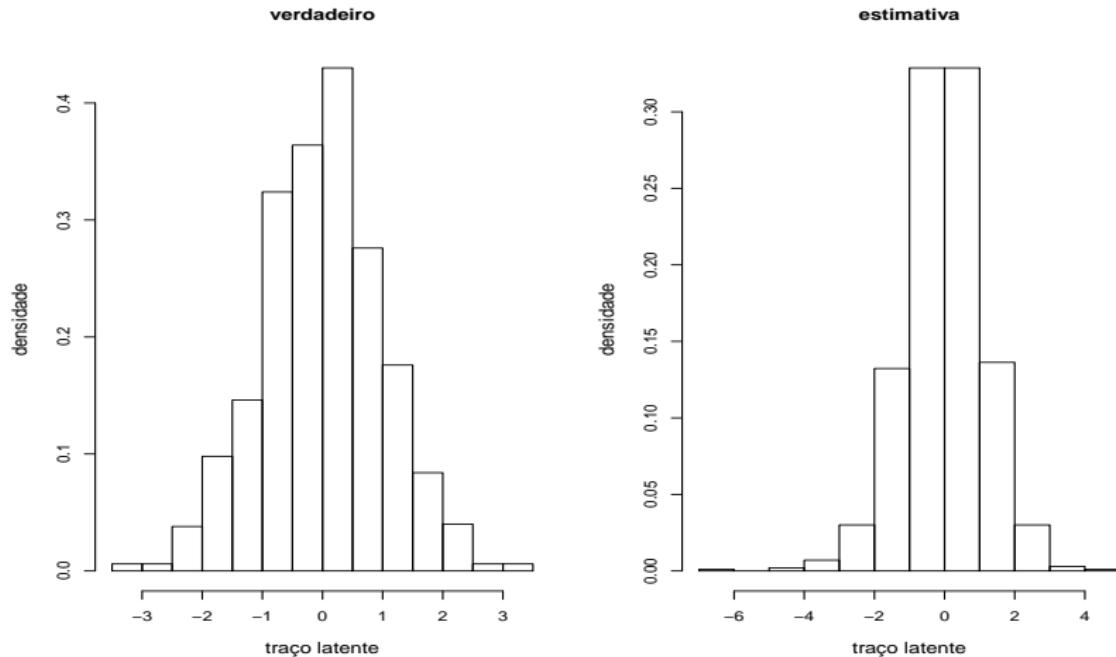
Modelo 3: parâmetro dos itens



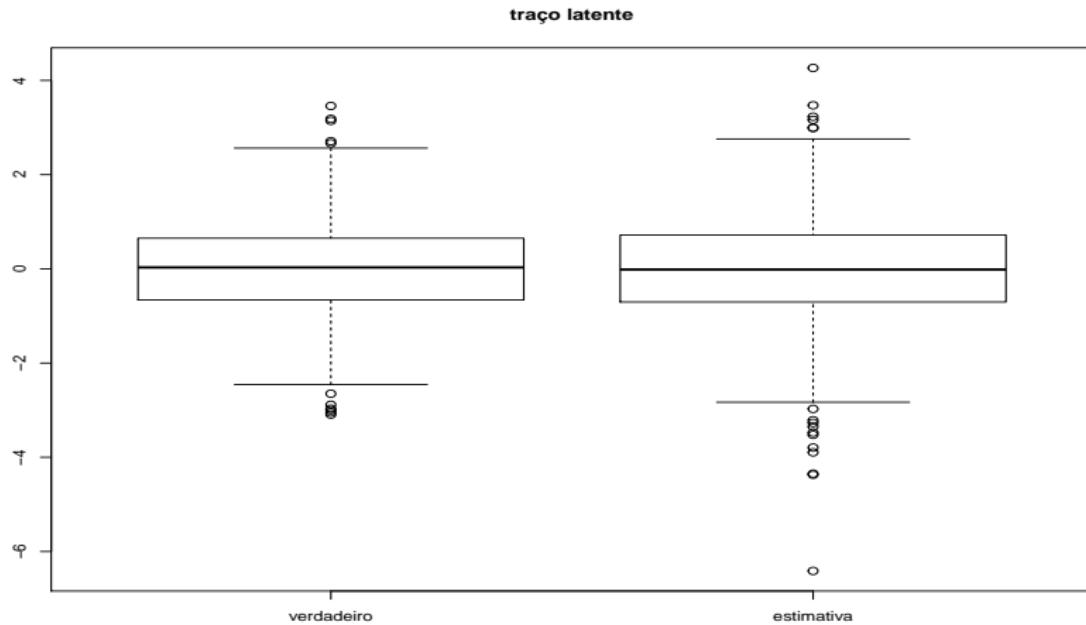
Modelo 3: traços latentes



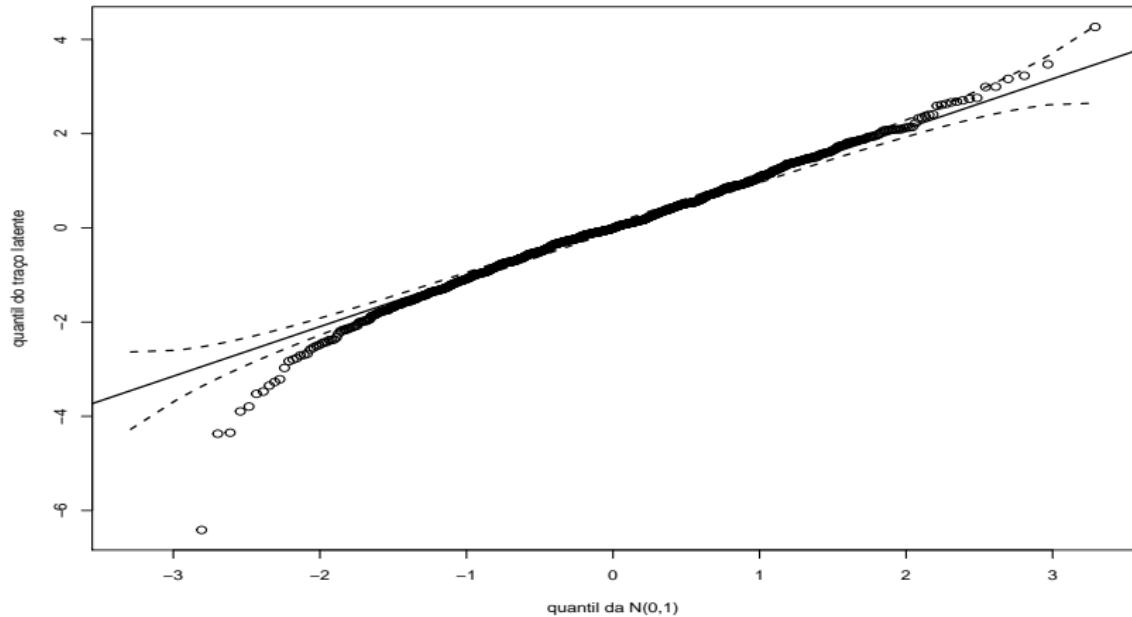
Modelo 3: traços latentes



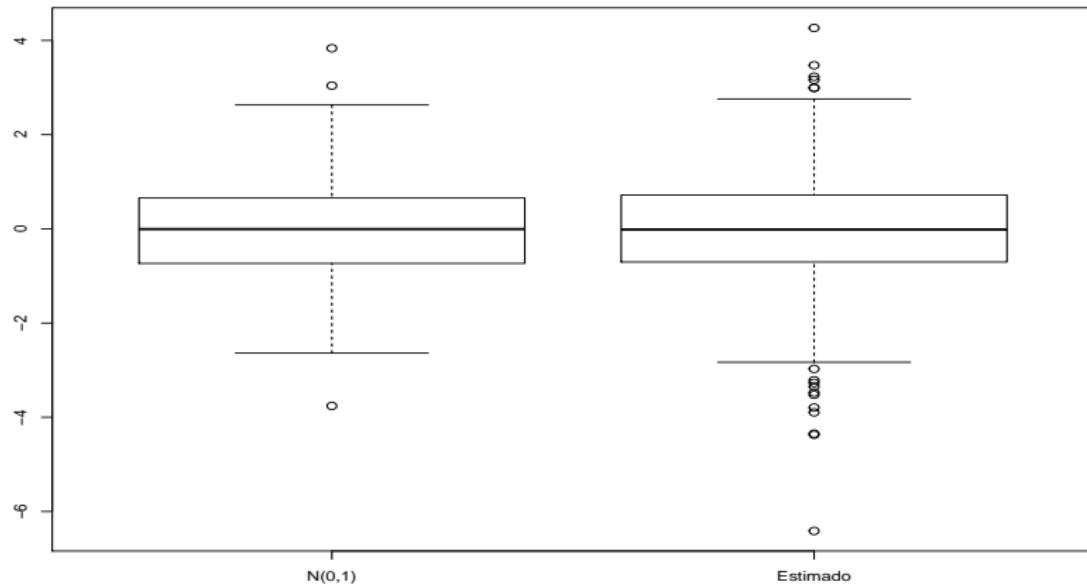
Modelo 3: traços latentes



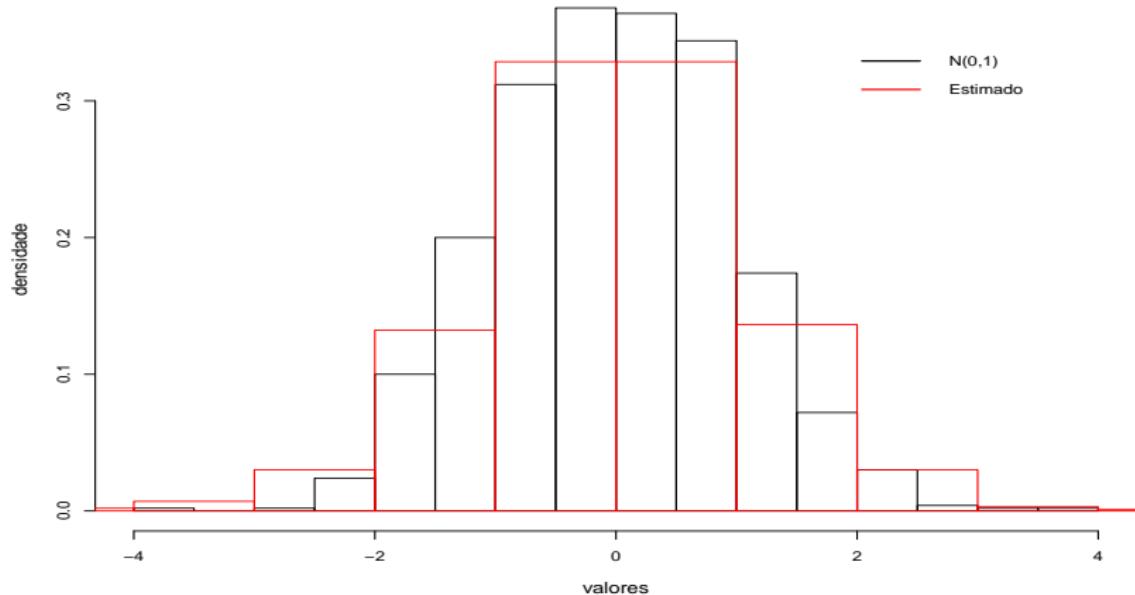
Modelo 3: traços latentes



Modelo 3: traços latentes



Modelo 3: traços latentes



Estimação da densidade dos traços latentes: modelo 1

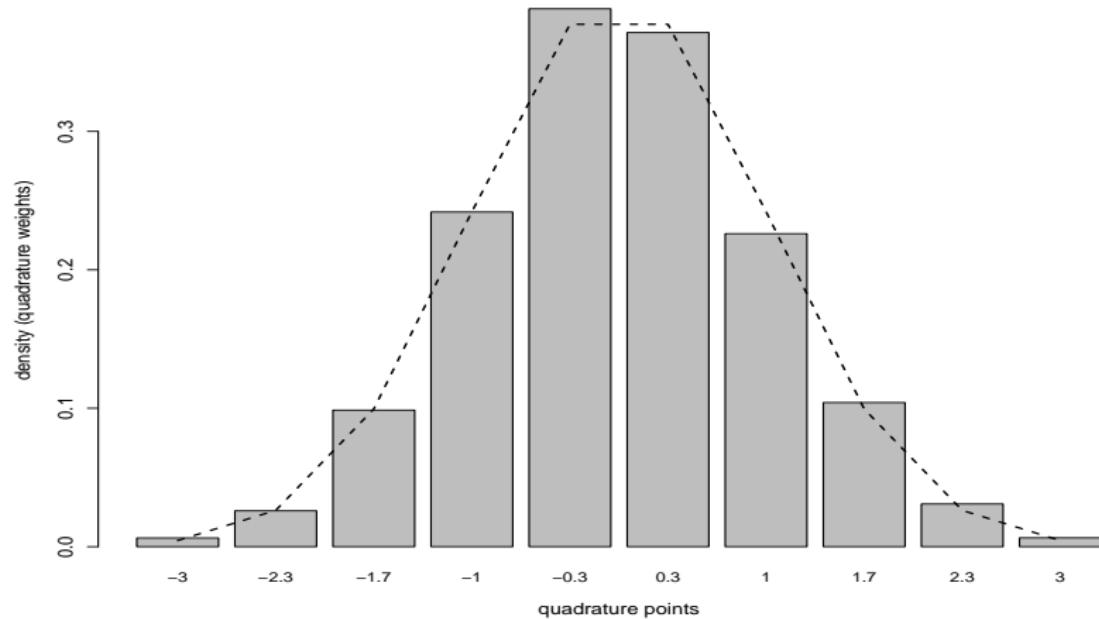
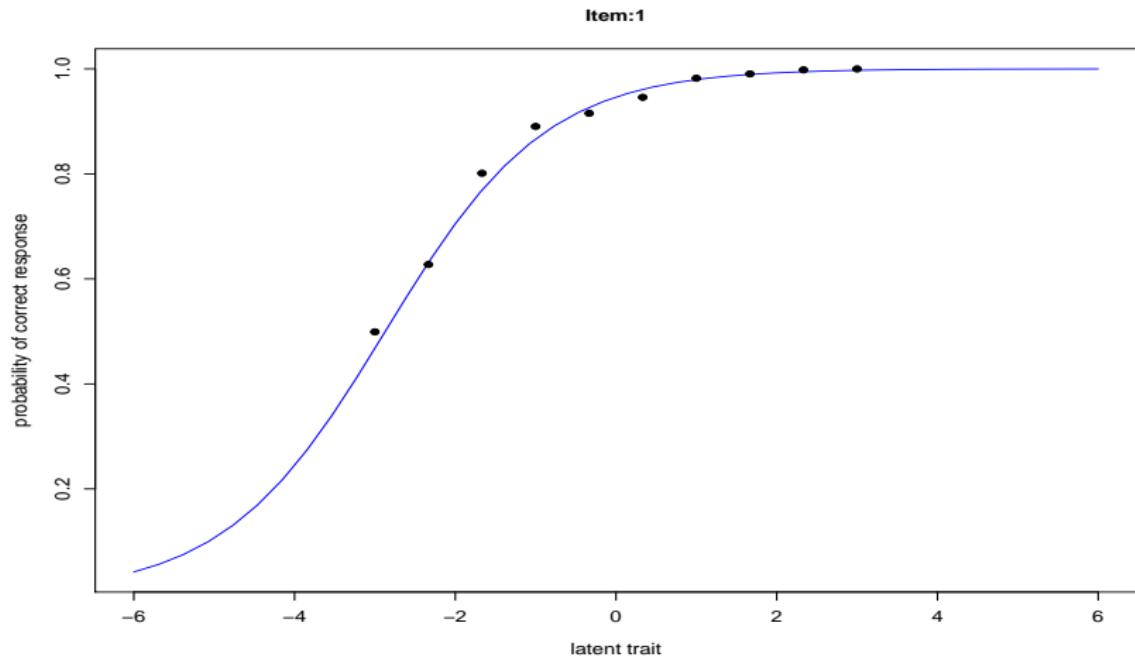
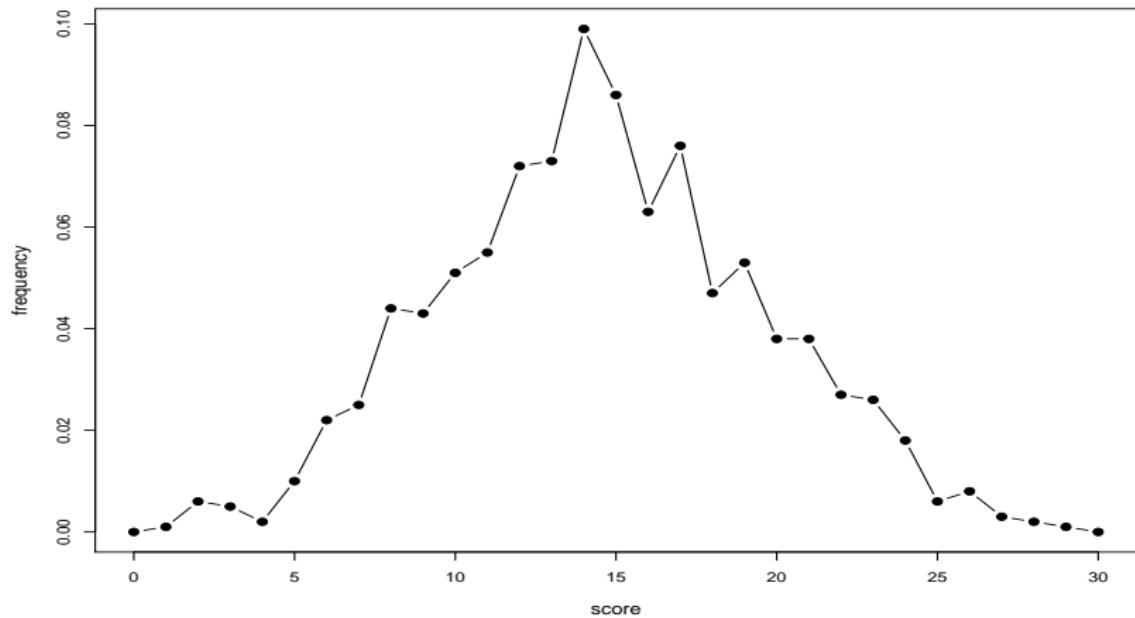


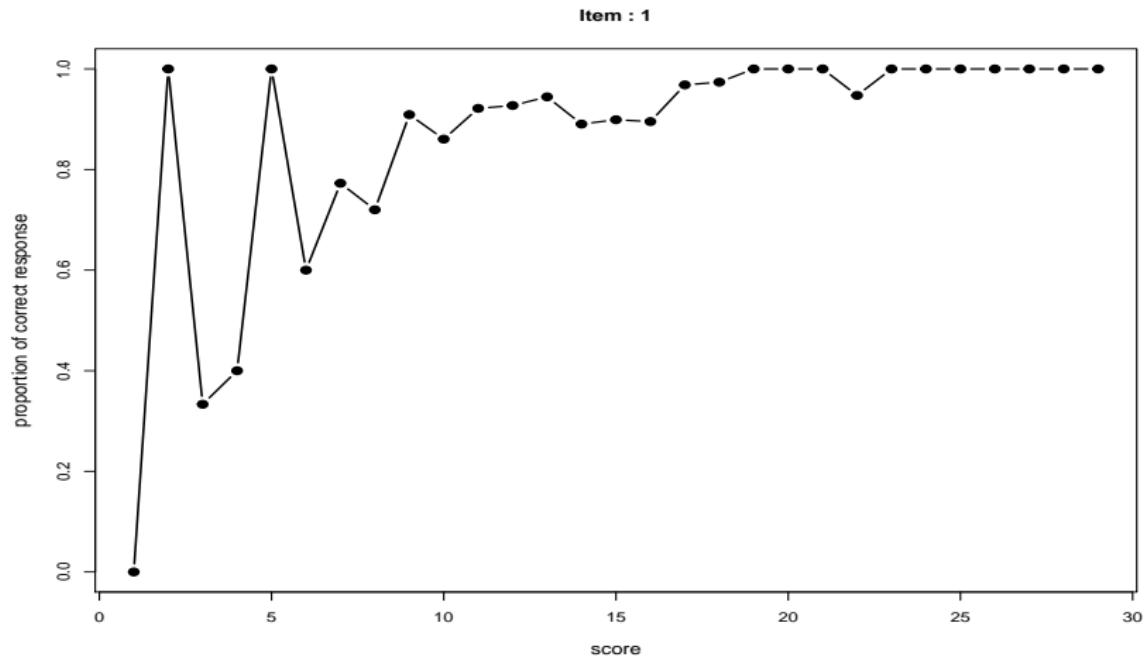
Gráfico de ajuste (probabilidade): modelo 1



Escores observados: modelo 1



Proporções observadas de resposta correta: modelo 1



Checagem preditiva 1

- Ajusta-se algum modelo e armazena-se as estimativas dos parâmetros $\tilde{\zeta}$ e $\tilde{\theta}$.
- Simula-se R amostras ($\mathbf{Y}^{(r)}$, $r = 1, 2, \dots, R$), a partir do modelo ajustado e das estimativas $\tilde{\zeta}$ e $\tilde{\theta}$.
- Para cada um das amostras $\mathbf{Y}^{(r)}$ calcula-se as quantidades de interesse, e.g, distribuição dos escores e proporção de resposta correta, para cada item, em função dos escores.

Checagem preditiva 1

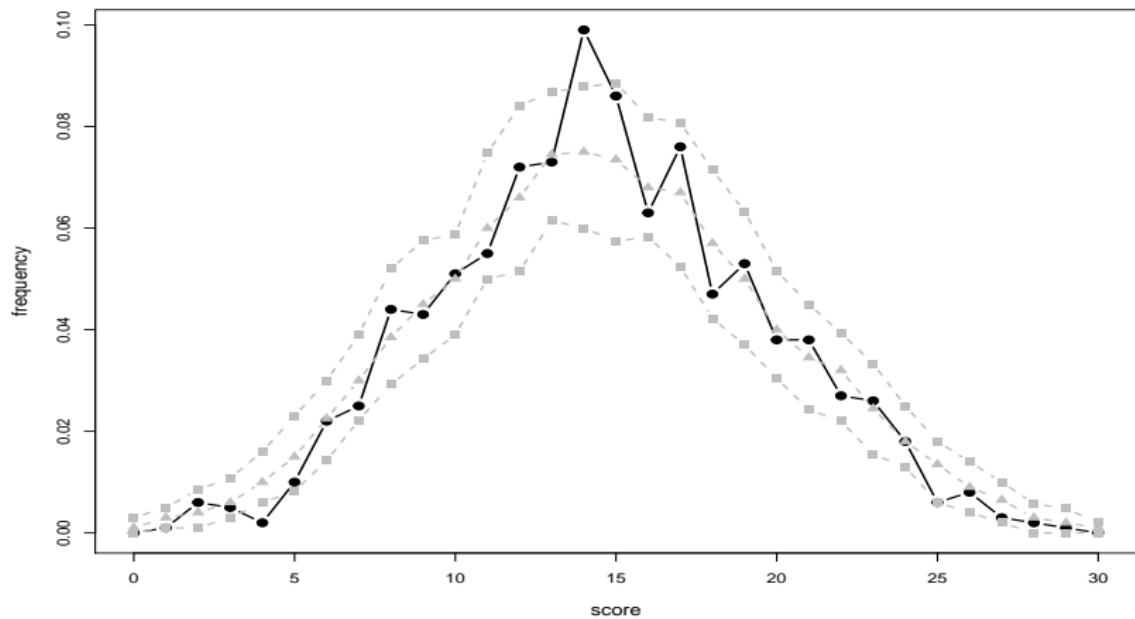
- Distribuição preditiva dos escores:

- Para cada $\mathbf{Y}^{(r)}$, calcular a distribuição dos escores, digamos $e_f^{(r)}$ (frequência absoluta ou relativa dos indivíduos que apresentarem nível de escore f , $f = 0, 1, \dots, I$).
- Para cada f , ordena-se, de forma crescente, ao longo dos valores r , os e_f , gerando-se as estatísticas de ordem para cada valor do escore, ou seja $(e_{f(r)})$.
- Calcula-se, para cada f , em função dos valores r , a mediana e os quantis de interesse.

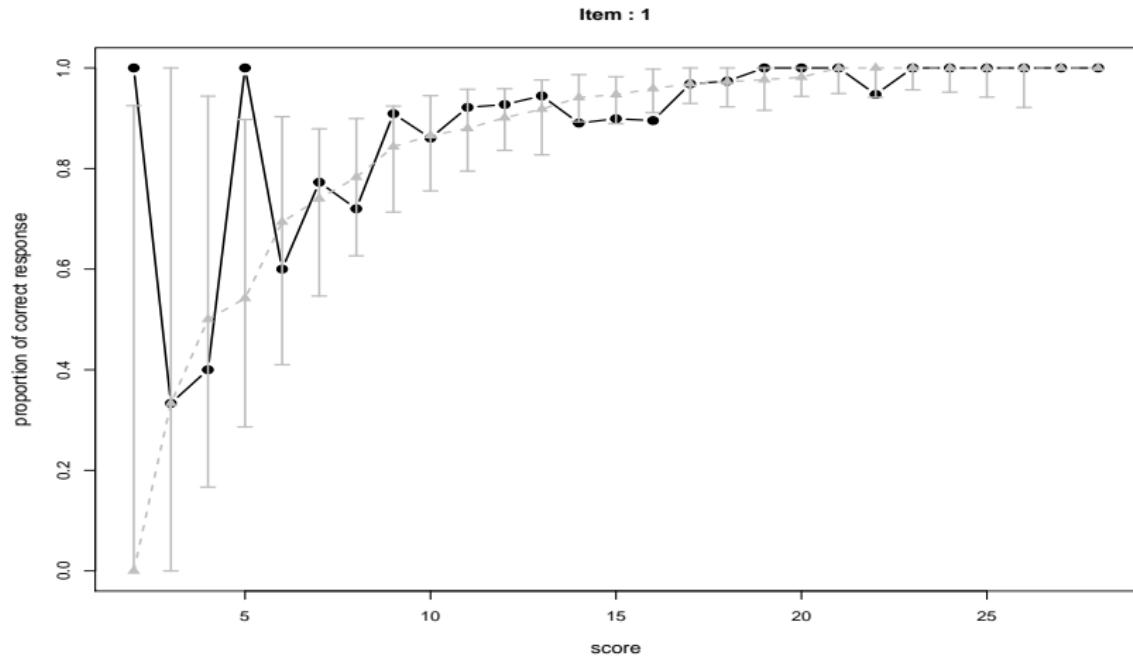
Checagem preditiva 1

- Distribuição preditiva das probabilidades de resposta correta:
 - Para cada $\mathbf{Y}^{(r)}$, calcula-se a proporção de resposta correta, por item para cada valor do escore, digamos $P_{if}^{(r)}$ (proporção de respostas corretas dos indivíduos que apresentaram nível de escore f , $f = 0, 1, \dots, I$).
 - Para cada f , ordena-se, de forma crescente, ao longo dos valores r , para cada item i , os $P_{if}^{(r)}$, gerando-se as estatísticas de ordem para as probabilidades para cada item e escore, ou seja $P_{if(r)}$.
 - Calcula-se, para cada f e i , em função dos valores r , a mediana e os quantis de interesse.

Escores observados e preditos: modelo 1



Proporções de respostas corretas obs. e pred.: modelo 1



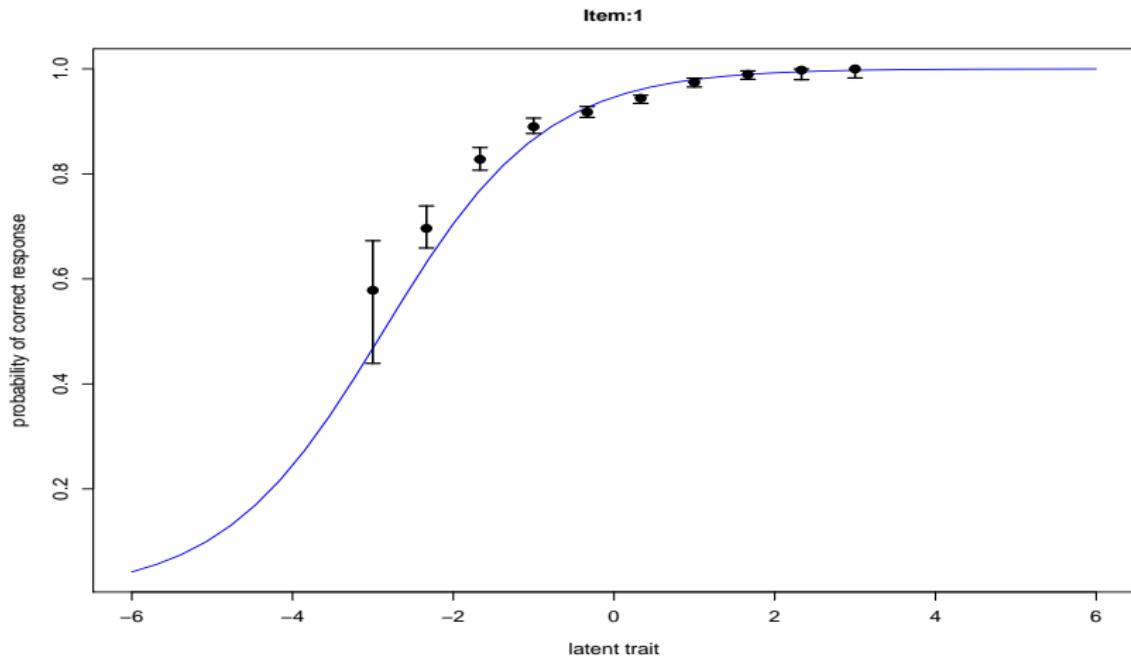
Checagem preditiva 2

- Ajusta-se algum modelo e armazena-se as estimativas dos parâmetros $\tilde{\zeta}$ e $\tilde{\theta}$.
- Simula-se R amostras ($\mathbf{Y}^{(r)}$, $r = 1, 2, \dots, R$), a partir do modelo ajustado e das estimativas $\tilde{\zeta}$ e $\tilde{\theta}$, para quais se ajustam, novamente, o modelo acima, obtendo-se $(\tilde{\zeta}^{(r)}, \tilde{\theta}^{(r)})$, $r = 1, 2, \dots, R$.
- Para cada um das amostras $\mathbf{Y}^{(r)}$ e estimativas $(\tilde{\zeta}^{(r)}, \tilde{\theta}^{(r)})$ calcula-se as quantidades de interesse, e.g., proporção de respostas correta, para cada item, em função dos traços latentes e resíduos apropriados.

Checagem preditiva 1

- Distribuição preditiva das probabilidades de resposta correta:
 - Para cada $\gamma^{(r)}$, calcula-se a proporção de respostas corretas, por item e para cada valor do ponto de quadratura, digamos $P_{if}^{(r)}$, $f = 0, 1, \dots, q$ (proporção de resposta correta dos indivíduos que apresentaram traço latente em torno do valor $\bar{\theta}_f$, $f = 0, 1, \dots, q$).
 - Para cada f , ordena-se, de forma crescente, ao longo dos valores r , para cada item i , os $P_{if}^{(r)}$, gerando-se as estatísticas de ordem para as probabilidades para cada item e ponto de quadratura, ou seja $(P_{if(r)})$.
 - Calcula-se, para cada f e i , em função dos valores r , a mediana e os quantis de interesse.

Probabilidades de respostas corr. obs. e pred.: modelo 1



- Baker, F. and Kim, Seock-Ho (2004). Item response theory : Parameter Estimation Techniques, Marcel Dekker, Inc.
- Azevedo, C. L. N. (2003). Métodos de estimação na Teoria da Resposta ao Item. Dissertação de mestrado, IME-USP.
- Andrade, D.F, Tavares, H. R. e Valle, R. C. (2000). Teoria da Resposta ao Item: conceitos e aplicações, 14^º SINAPE, ABE.
- Azevedo, C. L. N. and Andrade, D. F. (2010). An estimation method for latent trait and population parameters in Nominal Response Model. Brazilian Journal of Probability and Statistics, 24, 3.