

Metodologia de Estimação Clássica Implementada no Pacote ltm do R

Método de Estimação de Máxima
Verossimilhança aplicado no
pacote ltm do R

Modelos de Resposta ao Item

- Os problemas de estimação envolvem dois tipos de parâmetros, Itens e Habilidades.
- Divide-se em três situações:
 1. Quando se deseja estimar as habilidades;
 2. Quando se deseja estimar os parâmetros itens;
 3. Quando se deseja estimar os parâmetros dos itens e as habilidades dos indivíduos simultaneamente.
- Geralmente a estimação é feita pelo Método da Máxima Verossimilhança através da aplicação de algum processo iterativo, como o algoritmo *Newton-Raphson* ou *Scoring* de Fisher .

Método de Máxima Verossimilhança Marginal

- Criado por Bock&Lieberman – 1970
- Proposta desse método: Fazer a estimação em duas etapas:
 1. Primeiro os parâmetros dos itens
 2. Posteriormente, as habilidades.
- Como as habilidades não são conhecidas, precisaremos usar algum artifício de forma que a verossimilhança não seja mais função das habilidades.

- Artificio para eliminar as habilidades na verossimilhança: marginalizar a verossimilhança integrando-a com relação à distribuição da habilidade.
- De forma geral, consideremos que as habilidades θ_j , $j=1, \dots, n$ são realizações de uma variável aleatória θ com distribuição contínua e função densidade de probabilidade (fdp) $g(\theta|\eta)$, duplamente diferenciável, com as componentes de η conhecidas e finitas.
- Para o caso em que θ tem distribuição Normal, temos $\eta = (\mu, \sigma^2)$, onde μ é a média e σ^2 a variância das habilidades. Portanto, se desejarmos que os itens sejam estimados na métrica (0,1), deverá adotar $\mu = 0$ e $\sigma^2 = 1$.

Abordagem de Bock e Aitkin (1981)

- Proposta: Adotar independência entre os itens de forma a possibilitar que os itens sejam estimados individualmente.
- Sugere-se que a estimativa da máxima verossimilhança seja feita através do Algoritmo EM (Dempster, Laird & Rubin – 1977).
- As equações de estimação em forma de quadratura para os parâmetros a_i , b_i e c_i são respectivamente:

- $a_i = D(1 - c_i) \sum_{k=1}^q (\bar{\theta}_k - b_i) [r_{ki} - P_{ki} f_{ki}] W_{ki} = 0$

- $b_i = -D a_i (1 - c_i) \sum_{k=1}^q [r_{ki} - P_{ki} f_{ki}] W_{ki} = 0$

- $c_i = \sum_{k=1}^q [r_{ki} - P_{ki} f_{ki}] \frac{W_{ki}}{P_{ki}^*} = 0$

- Onde:

$$r_{ki}(\theta) = \sum_{j=1}^S r_j u_{ji} g_{jk}^*(\theta),$$

$$f_{ki}(\theta) = \sum_{j=1}^S r_j g_{jk}^*(\theta) \quad \text{e}$$

$$g_{jk}^*(\theta) = g_j^*(\bar{\theta}_k).$$

Aplicação do Algoritmo EM

- Processo iterativo para determinar estimativas de máxima verossimilhança de parâmetros de modelos de probabilidade na presença de variáveis aleatórias não observadas.
- Objetivo: obter estimativas de ζ na presença de variáveis não observadas θ .
- Sendo $u_{..}$ um vetor incompleto, e $(u_{..}, \theta)$ os dados completos. Temos $f(u_{..}, \theta | \zeta)$ a densidade conjunta dos dados completos. Os passos EM para $\hat{\zeta}^{(k+1)}$:
 1. **PASSO E (Esperança):** Calcular $E[\log f(u_{..}, \theta | \zeta) | u_{..}, \hat{\zeta}^{(k)}]$.
 2. **PASSO M (Maximização):** Obter $\hat{\zeta}^{(k+1)}$ que maximiza a função do PASSO E.

- Há três formas do algoritmo EM, distinguidas pela relação entre a função (densidade) de probabilidade e a forma da família exponencial:
 1. Aplicar quando a função é membro regular da família exponencial;
 2. Aplicar quando a função não é membro regular da família exponencial, mas é membro da família exponencial curvada;
 3. Aplicar quando a função não tem nenhuma relação com a família exponencial.

Descrivendo o Algoritmo

- Suponha que as habilidades são restritas a um conjunto de valores θ_k , $k=1, \dots, q$ com probabilidades π_k .
- Seja f_{ki} o número de indivíduos com habilidade θ_k respondendo ao item i e r_{ki} o número de indivíduos com habilidade θ_k respondendo corretamente ao item i .
- Desenvolvendo a distribuição conjunta de \mathbf{f} e \mathbf{r} , aplicando o logaritmo e aplicando a Esperança temos:

$$E[\log L(\zeta)] = \bar{C} + \sum_{i=1}^I \sum_{k=1}^q \{r_{ki} \log P_{ki} + (\bar{f}_{ki} - \bar{r}_{ki}) \log Q_{ki}\}$$

Assim, os Passos E e M são:

- **PASSO E:** Usar os pontos de quadratura $\bar{\theta}_k$, os pesos A_k , $k = 1, \dots, q$ e estimativas iniciais dos parâmetros dos itens, $\hat{\zeta}_i$; $i = 1, \dots, I$; para gerar $g_j^*(\bar{\theta}_k)$ e, posteriormente, \bar{f}_{ki} e \bar{r}_{ki} .
- **PASSO M:** Com \mathbf{r} e \mathbf{f} obtidos no Passo E, resolver as equações de estimação para ζ_i $i = 1, \dots, I$; usando o algoritmo Newton-Raphson ou “Scoring” de Fisher.

Pacote LTM para TRI - Software R

- Desenvolvido para análise dicotômica multivariada e para dados politômicos utilizando modelos de variáveis latentes.
- Estimativas são obtidas sobre máxima verossimilhança marginal usando quadratura de Gauss-Hermite.

Modelo de Variável Latente:

- Modelo de regressão multivariada que liga a categoria resposta à co-variável não observada.
- É necessária independência condicional, pois simplifica o processo de estimação.
- Nesse modelo as variáveis não observadas podem ser quantificadas pelas variáveis latentes.

- Ideia básica: encontrar, para um dado conjunto de variáveis resposta x_1, \dots, x_p , um conjunto de variáveis latentes Z_1, \dots, Z_Q ($Q < p$) com:

$$E(x_i|z) = g(\lambda_{i0} + \lambda_{i1}z_1 + \dots + \lambda_{iq}z_q), \quad i=1, \dots, p$$

Dados Dicotômicos

- Modelo para a probabilidade de resposta correta em cada item, dado o nível de habilidade z . Modelo geral:

$$P(x_{im} = 1|z_m) = c_i + (1 - c_i)g\{a_i(z_m - b_i)\}$$

Onde:

- x_{im} = é a variável dicotômica
- z_m = nível do examinador sobre a latente
- c_i = parâmetro relacionado à probabilidade do indivíduo com habilidade baixa responder o item corretamente
- a_i = parâmetro de discriminação
- b_i = parâmetro de dificuldade

Dados Politômicos

- Análise de variáveis politômicas está atualmente tratada por ltm usando o Modelo de Resposta Gradual.

$$P(x_{im} = k | z_m) = g(\eta_{ik}) - g(\eta_{ik+1})$$

onde $\eta_{ik} = a_i (z_m - b_{ik})$

Implementação do Pacote LTM

- Os parâmetros são estimados pela maximização da log-verossimilhança dos dados observados integrando as variáveis latentes.
- LTM tem quatro funções para ajustar o modelo:
 1. *rash()* - para modelo Rash
 2. *ltm()* - para modelos de Traço Latente
 3. *tpm()* - para modelos de três parâmetros
 4. *grm()* – para modelos de respostas graduais

- A maximização é conseguida utilizando *optim()* para *rash*, *tpm* e *grm*. Para *ltm* um algoritmo híbrido é adotado.
- Os valores iniciais são obtidos através do comando *start.val()*.
- Com o retorno dos objetos através das quatro funções anteriores de ajuste do modelo torna-se disponível os comandos: *print()*, *coef()*, *summary()*, *plot()*, *fitted()*, *loglik()*, *margins()*, *anova()*, *fator.scores()*.

Uso do Pacote LTM no R

- **Dados binários:** comando *descript()* para uma análise descritiva dos dados TRI, utiliza-se um dos quatro comandos anteriores para o ajuste do modelo, sendo o mais comum o *rash()*, *ltm()*. Utiliza-se o comando *information()* para verificar a área sob o teste da curva do item em um intervalo especificado.
- **Dados ordinais (politômicos):** uso do *descript()*. O comando *vcor.teste()* como um método alternativo para explorar o grau de associação entre os pares com coeficiente de correlação não paramétrica. Para o ajuste do modelo é comum a utilização do comando *grm()*.

Referências

- Andrade, D.F.; Tavares, H.R.; Valle, R.C. (2000) Teoria de Resposta ao Item: Conceitos e Aplicações.
- Rizopoulos, D. (2006) ltm: An R Package for Latent Variable Modeling and Item Response Theory Analyses