

Algoritmo EM: Parte 1

Prof. Caio Azevedo

Exemplo de Rao (tetranomial)

- Considere o exemplo descrito em Rao (1965, pp. 368-369), em que 197 animais são distribuídos multinomialmente em 4 categorias. Os dados observados consistem em

$$y = (y_1, y_2, y_3, y_4) = (125, 18, 20, 34).$$

- Se $Y \sim \text{Multonomial}_{p-1}(m, \theta_1, \theta_2, \dots, \theta_{p-1})$, então

$$f(y; \theta) = \frac{m!}{\prod_{i=1}^{p-1} y_i! (m - \sum_{i=1}^{p-1} y_i)!} \left(\prod_{i=1}^{p-1} \theta_i^{y_i} \right) \left(1 - \sum_{i=1}^{p-1} \theta_i \right)^{m - \sum_{i=1}^{p-1} y_i}$$

$$\prod_{i=1}^{m-1} \mathbb{1}_{\{0,1,\dots,m\}}(y_i) \mathbb{1}_{\{0,1,\dots,m\}}\left(\sum_{i=1}^{m-1} y_i\right)$$



Cont.

- Neste caso, tem-se o interesse em se ajustar o seguinte modelo genético:

$$\left(\frac{1}{2} + \frac{1}{4}\theta, \frac{1}{4}(1-\theta), \frac{1}{4}(1-\theta), \frac{\theta}{4} \right)$$

- Assim, tem-se que $(y_4 = 197 - y_1 - y_2 - y_3)$:

$$f(\mathbf{y}; \theta) = \frac{(y_1 + y_2 + y_3 + y_4)!}{y_1!y_3!y_3!y_4!} \left(\frac{1}{2} + \frac{1}{4}\theta \right)^{y_1} \left(\frac{1}{4}(1-\theta) \right)^{y_2} \left(\frac{1}{4}(1-\theta) \right)^{y_3} \left(\frac{\theta}{4} \right)^{y_4}$$

- Exercício: desenvolver e implementar o algoritmo Escore de Fisher para estimar θ , bem como implementar o TRV para testar a validade do modelo proposto.**

Cont.

- Para maximizar $l(\theta) = \ln L(\theta)$, vamos “aumentar” a dimensão do modelo multinomial, considerando

$$y_1 = x_1 + x_2, y_3 = x_2, y_4 = x_3, y_5 = x_4, \text{ assim}$$

$$f(\mathbf{x}; \theta) = \frac{(x_1 + x_2 + x_3 + x_4 + x_5)!}{x_1! x_2! x_3! x_4! x_5!} \left(\frac{1}{2}\right)^{x_1} \left(\frac{1}{4}\theta\right)^{x_2} \left(\frac{1}{4}(1-\theta)\right)^{x_3} \left(\frac{1}{4}(1-\theta)\right)^{x_4} \left(\frac{\theta}{4}\right)^{x_5}$$

- Resultado importante: pode-se provar que $f_{(y;\theta)} = \sum_{x \in Y(\Omega)} f(x; \theta)$. Neste caso, equivale a somar $f_{(x;\theta)}$ nos pares ordenados (x_1, x_2) , com a restrição de que $x_1 + x_2 = y$.

Cont.

- Temos que:

$$\begin{aligned}l(\theta) &= \text{const.} + x_1 \ln(1/2) + x_2 \ln\left(\frac{\theta}{4}\right) + x_3 \ln\left(\frac{1}{4} - \frac{\theta}{4}\right) \\ &+ x_4 \ln\left(\frac{1}{4} - \frac{\theta}{4}\right) + x_5 \ln\left(\frac{\theta}{4}\right)\end{aligned}$$

- Note que x_1, x_2 não são observáveis. Tomaremos a

$\mathcal{E}_{(X_1, X_2 | (y_1, y_2, y_3, y_4, \theta^{(t)}))}(l(\theta) | y_1, y_2, y_3, y_4, \theta^{(t)})$, em que $\theta^{(t)}$ é uma estimativa provisória de θ .

Cont.

- Note que $X_1|y_1, y_2, y_3, y_4, \theta^{(t)} \sim \text{binomial}\left(y_1 = 125, \frac{1/2}{1/2+\theta^{(t)}/4}\right)$ e $X_2|y_1, y_2, y_3, y_4, \theta^{(t)} \sim \text{binomial}\left(y_1 = 125, \frac{\theta^{(t)}/4}{1/2+\theta^{(t)}/4}\right)$.
- Seja $x_i^{(t)} = \mathcal{E}_{(X_1, X_2|(y_1, y_2, y_3, y_4, \theta^{(t)}))}(X_i|y_1, y_2, y_3, y_4, \theta^{(t)})$. Assim, temos que

$$x_1^{(t)} = 125 \frac{1/2}{1/2 + \theta^{(t)}/4}, x_2^{(t)} = 125 \frac{\theta^{(t)}/4}{1/2 + \theta^{(t)}/4}$$

- Dado $x_i^{(t)}$, a maximização com respeito a θ de $l(\theta)$, nos leva à:

$$\theta^{(t+1)} = \frac{x_2^{(t)} + 34}{x_2^{(t)} + 34 + 18 + 20}$$

Cont.

- Algoritmo EM. Dado um valor inicial para θ , digamos $\theta^{(0)}$, repita

Passo E: Calcule:

$$x_1^{(t)} = 125 \frac{1/2}{1/2 + \theta^{(t)}/4}, x_2^{(t)} = 125 \frac{\theta^{(t)}/4}{1/2 + \theta^{(t)}/4}$$

Passo M: Calcule:

$$\theta^{(t+1)} = \frac{x_2^{(t)} + 34}{x_2^{(t)} + 34 + 18 + 20}$$

até que algum critério de convergência seja obtido.

Cont.

- Histórico de iterações

t	$\theta^{(t)}$	$\theta^{(t)} - \theta^{(*)}$	$(\theta^{(t+1)} - \theta^{(*)})/(\theta^{(t+1)} - \theta^{(*)})$
0	0.500000000	0.126821498	0.1465
1	0.608247423	0.018574075	0.1346
2	0.624321051	0.002500447	0.1330
3	0.626488879	0.000332619	0.1328
4	0.626777323	0.000044176	0.1328
5	0.626815632	0.000005866	0.1328
6	0.626820719	0.000000779	-
7	0.626821395	0.000000104	-
8	0.626821484	0.000000014	-

- Seja $\mathbf{Y}_1, \dots, \mathbf{Y}_n$ uma a.a. de $\mathbf{Y} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$. Desejamos estimar $\boldsymbol{\mu}$ e $\boldsymbol{\Sigma}$ por máxima verossimilhança.

$$\mathbf{Y} = \begin{bmatrix} Y_{11} & Y_{21} & \dots & Y_{p1} \\ Y_{21} & Y_{22} & \dots & Y_{p2} \\ \vdots & \vdots & \ddots & \vdots \\ Y_{1n} & Y_{2n} & \dots & Y_{pn} \end{bmatrix}$$

- Se tivermos todas as observações, então $\hat{\boldsymbol{\mu}} = \frac{1}{n} \sum_{j=1}^n \mathbf{Y}_j$ e $\boldsymbol{\Sigma} = \frac{1}{n} \sum_{j=1}^n (\mathbf{Y}_j - \bar{\mathbf{Y}})' (\mathbf{Y}_j - \bar{\mathbf{Y}})$.
- Suponha que $p = 2$ e que, para $m \ll n$ indivíduos, exatamente uma das observações esteja faltando (Y_{1j} ou Y_{j2}). Por simplicidade, suponha que $\boldsymbol{\Sigma}$ é conhecida.

- Matriz de dados.

$$\mathbf{Y} = \begin{bmatrix} Y_{11} & - \\ Y_{21} & Y_{22} \\ \vdots & \vdots \\ - & Y_{pn} \end{bmatrix}$$

- Imputar as observações perdidas usando o fato de que

$Y_{j1}|y_{j2}, \boldsymbol{\mu}, \boldsymbol{\Sigma} \sim N_1(\bar{\mu}_1, \bar{\sigma}_1^2)$, em que $\bar{\mu}_1 = \mu_1 + \sigma_{12} (\sigma_2^2)^{-1} (y_{j2} - \mu_2)$
e $\bar{\sigma}_1^2 = \sigma_1^2 - (\sigma_{12})^2 (\sigma_2^2)^{-1}$.

$Y_{j2}|y_{j1}, \boldsymbol{\mu}, \boldsymbol{\Sigma} \sim N_1(\bar{\mu}_2, \bar{\sigma}_2^2)$, em que $\bar{\mu}_2 = \mu_2 + \sigma_{12} (\sigma_1^2)^{-1} (y_{j1} - \mu_1)$
e $\bar{\sigma}_2^2 = \sigma_2^2 - (\sigma_{12})^2 (\sigma_1^2)^{-1}$.

■ Log-verossimilhança

$$l(\boldsymbol{\mu}) = \text{const.} - 0.5 \sum_{j=1}^n (\mathbf{y}' \boldsymbol{\Sigma}^{-1} \mathbf{y} + \boldsymbol{\mu}' \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu} - 2 \mathbf{y}' \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu})$$

$$\frac{\partial l(\boldsymbol{\mu})}{\partial \boldsymbol{\mu}} = -0.5 \sum_{j=1}^n (2 \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu} - 2 \boldsymbol{\Sigma}^{-1} \mathbf{y})$$

- “Máxima verossimilhança com imputação”. Inicie o processo com valores iniciais $\boldsymbol{\mu}^{(t)}$.
- Cálculo da esperança (Passo E): Calcular, conforme a observação faltante para cada indivíduo (caso necessário),

$$y_{j1}^* = \mathcal{E}(Y_{j1}|y_{j2}, \boldsymbol{\mu}^{(t)}, \boldsymbol{\Sigma}^{(t)}) = \mu_1^{(t)} + \sigma_{12}^{(t)} \left(\sigma_2^{2(t)} \right)^{-1} \left(y_{j2} - \mu_2^{(t)} \right)$$

$$y_{j2}^* = \mathcal{E}(Y_{j2}|y_{j1}, \boldsymbol{\mu}^{(t)}, \boldsymbol{\Sigma}^{(t)}) = \mu_2^{(t)} + \sigma_{12}^{(t)} \left(\sigma_1^{2(t)} \right)^{-1} \left(y_{j1} - \mu_1^{(t)} \right)$$

- Maximização da log-verossimilhança (Passo M): Com a matriz de dados completa, calcular

$$\hat{\boldsymbol{\mu}}^{(t+1)} = \frac{1}{n} \sum_{j=1}^n \mathbf{Y}_j^{(*)} = \bar{\mathbf{Y}}^{(t)} \text{ e}$$

Algoritmo EM

- Seja \mathbf{Y} o conjunto de variáveis observadas e \mathbf{Y}^* o conjunto de variáveis não observadas (não observáveis, dados faltantes).
- Em geral, \mathbf{Y} é chamado de dados incompletos e $(\mathbf{Y}, \mathbf{Y}^*)$ são os dados completos.
- Seja $l(\boldsymbol{\theta})$ a logverossimilhança em que $\boldsymbol{\theta} \in \Theta \subset \mathcal{R}^p$ é o conjunto de parâmetros a ser estimado.

Cont.

- Seja $\theta^{(0)}$ valores iniciais apropriados como estimativas de θ . Repita o processo a seguir:

Passo E: Calcule a esperança condicional (na log-verossimilhança) dos dados faltantes condicionado as variáveis observadas e à estimativas provisórias de $\theta^{(t)}$, ou seja $\mathcal{E}_{Y_* | Y_b, \theta^{(t)}}(l(\theta) | \mathbf{y}, \theta^{(t)})$.

Passo M: Maximizar a esperança acima em relação à θ .

até que algum critério de convergência seja alcançado.

Estrutura do algoritmo EM

- Seja $l(\theta, \mathbf{y}, \mathbf{y}^*)$ a log-verossimilhança aumentada e $\theta^{(t)}$ estimativas provisórias para θ . O algoritmo EM pode ser resumido nos seguintes passos

Passo E: Calcule a esperança condicional (na log-verossimilhança) dos dados faltantes condicionado as variáveis observadas e às estimativas provisórias de $\theta^{(t)}$, ou seja

$$Q(\theta|\theta^{(t)}) = \mathcal{E} [l(\theta, \mathbf{y}, \mathbf{y}^*)|\mathbf{y}, \theta]$$

Passo M: Maximizar a esperança acima em relação a θ ou seja, obter

$$\theta^{(t+1)} = \operatorname{argmax}_{\theta} Q(\theta|\theta^{(t)})$$

até que algum critério de convergência seja alcançado.

Observações

- O cálculo das esperanças necessárias podem ser complicadas, necessitando do emprego de aproximações analíticas ou numéricas.
- Para a maximização pode ser necessário o emprego de métodos numéricos.
- Na família exponencial as contas ficam mais simples.
- A utilização de valores iniciais apropriados para θ auxilia na convergência do algoritmo EM.
- A introdução de variáveis “aumentadas” apropriadas, é outro fator de importância na convergência e obtenção de estimativas acuradas.

Regressão Probit

- Seja Y_1, \dots, Y_n uma a.a. de $Y \sim \text{Bernoulli}(p_i)$, $p_i = \Phi(\beta_0 + X_i\beta_1)$.
Desejamos estimar (β_0, β_1) .
- Verossimilhança:

$$L(\beta) = \prod_{i=1}^n p_i^{y_i} (1 - p_i)^{1-y_i}$$

- Defina:

$$Y_i = I_{(Z_i > 0)}$$

$$Z_i \sim N(\beta_0 + X_i\beta_1, 1)$$

Regressão Probit

- Assim, pode-se provar que

$$Z_i | y_i, x_i, \beta = \begin{cases} N_{(0, \infty)}(\beta_0 + X_i \beta_1, 1) & \text{se } y_i = 1 \\ N_{(-\infty, 0)}(\beta_0 + X_i \beta_1, 1) & \text{se } y_i = 0 \end{cases} \quad (1)$$

- Assim, pode-se trabalhar com a seguinte verossimilhança

$$L(\beta, \mathbf{z}, \mathbf{y}) \propto \prod_{i=1}^n \exp \left[-0,5 (z_i - \beta_0 - X_i \beta_1)^2 \right]$$

Cont.

- Resumindo:

$$Y_i \sim \text{Bernoulli}(p_i)$$

$$Y_i | z_i = \begin{cases} 1, & \text{se } z_i \geq 0, \\ 0, & \text{se } z_i < 0 \end{cases}$$

$$Z_i | y_i \sim N(\mathbf{1}_{(z_i \geq 0, y_i = 1, z_i < 0, y_i = 0)})(\beta_0 + X_i \beta_1, 1)$$

- Logo, a verossimilhança completa (dados aumentados) é dada por

$$f(\mathbf{z}, \mathbf{y}, \boldsymbol{\beta}) = L(\boldsymbol{\beta}, \mathbf{z}, \mathbf{y}) \propto \prod_{i=1}^n \exp \left[-0,5 (z_i - \beta_0 - X_i \beta_1)^2 \right]$$

Cont.

- Log-verossimilhança:

$$L(\beta) = \text{const.} - \exp \left[-0.5 (\mathbf{z} - \mathbf{X}\beta)' (\mathbf{z} - \mathbf{X}\beta) \right]$$

- É necessário calcular apenas $\mathcal{E}(Z_i | y_i, x_i, \beta^{(t)})$

Cont.

■ Algoritmo EM:

Passom E: Calcular

$$\mathcal{E}(Z_i | y_i, x_i, \boldsymbol{\beta}^{(t)}) = \begin{cases} \mu_i(t) + \frac{\phi(-\mu_i(t))}{1 - \Phi(-\mu_i(t))}, & \text{se } y_i = 1 \\ \mu_i(t) - \frac{\phi(-\mu_i(t))}{\Phi(-\mu_i(t))}, & \text{se } y_i = 0 \end{cases}$$

em que $\mu_i^{(t)} = \beta_0^{(t)} + X_i \beta_1^{(t)}$, ϕ e Φ são a densidade e a fda da distribuição $N(0, 1)$.

Passom E: Calcular

$$\boldsymbol{\beta}^{(t+1)} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Z}$$

Mistura finita de normais

- Amostra aleatória de $Y \sim MFN_2(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, p)$, ou seja

$$f(y; \theta) = pf_{Y_1}(y; \mu_1, \sigma_1^2) + (1 - p)f_{Y_2}(y; \mu_2, \sigma_2^2)$$

$$\theta = (p, \mu_1, \mu_2, \sigma_1^2, \sigma_2^2), p \in (0, 1), \mu_i \in \mathcal{R}, \sigma_i^2 \in \mathcal{R}^2, i = 1, 2$$

em que $f_{Y_i}(\cdot; \cdot)$ é a fdp de uma distribuição $N(\mu_i, \sigma_i^2)$, $i = 1, 2$.

Aplicação do algoritmo EM

- Defina uma variável latente Z , tal que $Z \sim \text{Bernoulli}(p)$ e:

$$Y = \begin{cases} Y_1, & \text{se } Z = 1 \\ Y_2 & \text{se } Z = 0 \end{cases}$$

- Assim, $Y|z = 1 \sim N(\mu_1, \sigma_1^2)$ e $Y|z = 0 \sim N(\mu_2, \sigma_2^2)$.
- Logo, $Z|y \sim \text{Bernoulli}(p^*)$, em que $p^* = \frac{pf_{Y_1}(y; \mu_1, \sigma_1^2)}{pf_{Y_1}(y; \mu_1, \sigma_1^2) + (1-p)f_{Y_2}(y; \mu_2, \sigma_2^2)}$
- Considerando, agora uma amostra aleatória de Y , Y_1, Y_2, \dots, Y_n e definindo Z_i para cada Y_i .

Cont.

- Logo:

$$f(\mathbf{y}, \mathbf{z} | \boldsymbol{\theta}) = \prod_{i=1}^n \left\{ (p f_{Y_1}(y_i; \mu_1, \sigma_1^2))^{z_i} ((1-p) f_{Y_2}(y_i; \mu_2, \sigma_2^2))^{1-z_i} \right\}$$

- A log-verossimilhança é dada por:

$$\begin{aligned} l(\boldsymbol{\theta}, \mathbf{y}, \mathbf{z}) &= \sum_{i=1}^n \left\{ z_i (\ln p + \ln f_{Y_1}(y_i; \mu_1, \sigma_1^2)) \right. \\ &\quad \left. + (1 - z_i) (\ln(1-p) + \ln f_{Y_2}(y_i; \mu_2, \sigma_2^2)) \right\} \end{aligned}$$

Cont.

■ Portanto

$$Q(\boldsymbol{\theta}|\boldsymbol{\theta}^{(t)}) = \sum_{i=1}^n \{z_i^{(t)} (\ln p + \ln f_{Y_1}(y_i; \mu_1, \sigma_1^2)) + (1 - z_i^*) (\ln(1 - p) + \ln f_{Y_2}(y_i; \mu_2, \sigma_2^2))\}$$

em que

$$z_i^{(t)} = \mathcal{E}(Z_i|y_i, \boldsymbol{\theta}^{(t)}) = p_i^{(t)} = \frac{p^{(t)} f_{Y_1}(y_i; \mu_1^{(t)}, \sigma_1^{2(t)})}{p^{(t)} f_{Y_1}(y_i; \mu_1^{(t)}, \sigma_1^{2(t)}) + (1 - p^{(t)}) f_{Y_2}(y_i; \mu_2^{(t)}, \sigma_2^{2(t)})}$$

Cont.

- Por outro lado, maximizando-se $Q(\boldsymbol{\theta}|\boldsymbol{\theta}^{(t)})$, tem-se que

$$\mu_j^{(t+1)} = \frac{\sum_{i=1}^n z_i^{(t)} y_i}{\sum_{i=1}^n z_i^{(t)}}$$

$$\sigma_j^{2(t+1)} = \frac{\sum_{i=1}^n z_i^{(t)} (y_i - \mu_j^{(t+1)})^2}{\sum_{i=1}^n z_i^{(t)}}$$

$$p^{(t+1)} = \frac{1}{n} \sum_{i=1}^n z_i^{(t)}$$

Modelo linear misto

- Suponha que $i = 1, \dots, n$ indivíduos sejam estudados durante $j = 1, \dots, t$ instantes de avaliação, em relação à uma característica Y_{ij} .
- Seja

$$Y_{ij} = \mu_j + b_i + \xi_{ij}$$

$$b_i \stackrel{iid}{\sim} N(0, \psi)$$

$$\xi_{ij} \stackrel{iid}{\sim} N(0, \sigma^2)$$

$$\xi_{ij} \perp b_i, \forall i, j$$

Cont.

- Desejamos estimar $\theta = (\mu_j, \psi, \sigma^2)$ e prever b_i (variáveis latentes).
- Uma possibilidade: verossimilhança marginal. Necessário obter a distribuição marginal de \mathbf{Y} em relação à \mathbf{b} .
- Outra possibilidade: considerar \mathbf{b} como os dados faltantes.

Cont.

- Verossimilhança aumentada:

$$L(\boldsymbol{\theta}; \mathbf{y}, \mathbf{b}) \propto \left\{ \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i,j} (y_{ij} - \mu_j - b_i)^2 \right\} \right\} \\ \times \left\{ \exp \left\{ -\frac{1}{2\psi} \sum_i (b_i)^2 \right\} \right\} (\sigma^2)^{-nt/2} \psi^{-n/2}$$

Cont.

- Log-verossimilhança:

$$\begin{aligned}
 l(\boldsymbol{\theta}; \mathbf{y}, \mathbf{b}) &= -\frac{1}{2\sigma^2} \sum_{i,j} ((y_{ij} - \mu_j)^2 - 2(y_{ij} - \mu_j)b_i + b_i^2) \\
 &\quad - \frac{1}{2\psi} \sum_i (b_i)^2 - \frac{nt}{2} \ln \sigma^2 - \frac{n}{2} \ln \psi + \text{const}
 \end{aligned}$$

- Portanto:

$$\begin{aligned}
 Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(t)}) &= -\frac{1}{2\sigma^2} \sum_{i,j} \left((y_{ij} - \mu_j)^2 - 2(y_{ij} - \mu_j)b_i^{(t)} + b_i^{2(t)} \right) \\
 &\quad - \frac{1}{2\psi} \sum_i (b_i)^{2(t)} - nt \ln \sigma^2 - t \ln \psi + \text{const}
 \end{aligned}$$

Cont.

- Em que

$$b_i^{(t)} = \mathcal{E}(b_i | \mathbf{y}_{i.}, \boldsymbol{\mu}^{(t)}, \sigma^{2(t)}, \psi^{(t)})$$

$$b_i^{2(t)} = \mathcal{E}(b_i^{(2)} | \mathbf{y}_{i.}, \boldsymbol{\mu}^{(t)}, \sigma^{2(t)}, \psi^{(t)})$$

Cont.

- Além disso

$$b_i | \mathbf{y}_i, \boldsymbol{\mu}, \sigma^2, \psi \stackrel{\text{ind.}}{\sim} N(\mu_{b_i}^*, \psi^*),$$

em que

$$\psi^* = \left(\frac{1}{\psi} + \frac{t}{\sigma^2} \right)^{-1}$$
$$\mu_{b_i}^* = (\psi^*)^{-1} \left(\frac{t}{\sigma^2} (\bar{y}_i - \bar{\mu}) \right)$$

$$\bar{y}_i = \frac{1}{t} \sum_{j=1}^t y_{ij}; \bar{\mu} = \frac{1}{t} \sum_{j=1}^t \mu_j$$

Cont.

- Por fim, maximizando-se a log-verossimilhança em relação à θ , temos

$$\mu_j^{(t+1)} = \frac{1}{n} \sum_i (y_{ij} - b_i^{(t)})$$

$$\sigma^{2(t+1)} = \frac{1}{nt} \left((y_{ij} - \mu_j^{(t+1)})^2 - 2(y_{ij} - \mu_j^{(t+1)})b_i^{(t)} + b_i^{2(t)} \right)$$

$$\psi^{(t+1)} = \frac{1}{n} \sum_j (b_i^{2(t)})$$

Cálculo do Erro-padrão

- Sabemos que, sob certas condições de regularidade o emv de θ , $\hat{\theta}$ é tal que, para n suficientemente grande $\hat{\theta} \approx N_p \left(\theta, \mathbf{I}(\theta)^{-1} \right)$.
- O estimador obtido pelo EM, é um estimador de máxima verossimilhança. Portanto, sob as condições mencionadas, apresenta a propriedade acima.
- Como obter a Informação de Fisher (observada) no contexto do algoritmo EM.

Cont.

- Sejam $l(\boldsymbol{\theta}, \mathbf{y}) = l$ e $l(\boldsymbol{\theta}, \mathbf{y}, \mathbf{y}^*) = l^*$, respectivamente, a log-likelihood associada aos dados incompletos e aos dados completos.
- Sejam ainda

$$S(\boldsymbol{\theta}) = \frac{\partial^p}{\partial \boldsymbol{\theta}^p} l; S(\boldsymbol{\theta})^* = \frac{\partial^p}{\partial \boldsymbol{\theta}^p} l^*$$

$$H(\boldsymbol{\theta}) = \frac{\partial^2 p}{\partial \boldsymbol{\theta}^p \partial \boldsymbol{\theta}^{p'}} l; H(\boldsymbol{\theta})^* = \frac{\partial^2 p}{\partial \boldsymbol{\theta}^p \partial \boldsymbol{\theta}^{p'}} l^*$$

Cont.

- Pode-se provar que, a Informação de Fisher observada $I(\boldsymbol{\theta})^\circ$ é pode ser aproximada por (identidade de Louis)

$$\begin{aligned} I(\boldsymbol{\theta})^\circ &= \mathcal{E}(-H(\boldsymbol{\theta})^* | \mathbf{y}, \boldsymbol{\theta}) - \mathcal{E}(S(\boldsymbol{\theta})^* S(\boldsymbol{\theta})^{*'} | \mathbf{y}, \boldsymbol{\theta}) \\ &\quad + S(\boldsymbol{\theta}) S(\boldsymbol{\theta})') \end{aligned}$$

- Seja $\tilde{\boldsymbol{\theta}}$ a estimativa obtida via algoritmo EM, então:

$$I(\tilde{\boldsymbol{\theta}})^\circ = \mathcal{E}(-H(\tilde{\boldsymbol{\theta}})^* | \mathbf{y}, \boldsymbol{\theta}) - \mathcal{E}(S(\tilde{\boldsymbol{\theta}})^* S(\tilde{\boldsymbol{\theta}})^{*'} | \mathbf{y}, \boldsymbol{\theta})$$

Cont.

- Pois $S(\tilde{\theta}) = \mathbf{0}$.
- Como, também $S(\tilde{\theta})^* = \mathbf{0}$, temos que

$$I(\tilde{\theta})^o = \mathcal{E} \left(-H(\tilde{\theta})^* | \mathbf{y}, \theta \right) - \text{Cov} \left(S(\tilde{\theta})^* | \mathbf{y}, \theta \right)$$