

ALGORITMOS PARA DADOS AUMENTADOS

1. INTRODUÇÃO

Dois algoritmos baseados na consideração de dados latentes. Temos os dados efetivamente observados, Y , e de uma maneira conveniente aumentamos esses dados, introduzindo os dados, Z , chamamos latentes ou não observados, de modo a facilitar o procedimento de cálculo da verossimilhança ou da densidade a posteriori.

O princípio de "aumento dos dados" pode ser enunciado da seguinte forma: "aumentar" ao dados observados Y , com dados latentes Z de tal forma que $P(\theta/y,z)$ ou $L(\theta/y,z)$ sejam simples.

ALGORITMO EM: maximizar a verossimilhança dos dados observados utilizando-se os dados completos $X=\{Y,Z\}$ de maneira conveniente.

ALGORITMO DE DADOS AUMENTAODS: maximizar $P(\theta/y)$ utilizando $P(\theta/y,z)$.

EXEMPLO 1: suponha que se observe um processo periodicamente (por ex., peixes presos em armadilhas) que se acumule em intervalos regulares:

x_1, x_2, \dots, x_7 : quantidade nos dias 1, 2, ..., 7.

$$y_1 = x_1 + x_2$$

$y_2 = x_3 \rightarrow X = (x_1, x_2, \dots, x_7)$: dados completos (o que deveria ter sido observado)

$y_3 = x_4 + x_5 \quad Y = (y_1, y_2, \dots, y_4)$: dados incompletos (o que foi observado)

$$y_4 = x_6 + x_7$$

2. ALGORITMO EM

$X = (x_1, x_2, \dots, x_n)'$ do modelo $f(x/\theta) \rightarrow L(\theta/x)$.

Suponha que não observamos X completamente, mas alguma função de X , digamos $Y=h(X)$. Dizemos que

X : dados completos

$Y=h(X)$: dados incompletos

A **verossimilhança** dos dados observados(incompletos) Y é dada por

$$L(\theta/Y) = \int_{\psi(y)} L(\theta/X) dX \quad (1)$$

Onde $\psi(y)$: parte do espaço amostral ψ de X determinada pela equação $y=h(x)$.

O algoritmo EM (**E**: esperança, **M**: maximização) é um procedimento iterativo segundo o qual encontramos o valor de θ que maximiza a verossimilhança dos dados observados, $L(\theta/Y)$, usando $L(\theta/X)$ de maneira conveniente. "conveniente" significa escolher $L(\theta/X)$ que fornece $L(\theta/Y)$, utilizando (1), de modo a tornar o problema fácil.

EXEMPLO 2: problema genético estudado.

197 animais distribuídos em 4 classes:

$(y_1, y_2, y_3, y_4)'$ segundo as prob. $\frac{\theta+2}{4}$, $\frac{1-\theta}{4}$, $\frac{1-\theta}{4}$, $\frac{\theta}{4}$,

$0 < \theta < 1$.

$Y = (125, 18, 20, 34) = (y_1, y_2, y_3, y_4)'$

A verossimilhança dos dados incompletos, é dada por

$$L(\theta/Y) = \frac{(y_1 + y_2 + y_3 + y_4)!}{y_1! y_2! y_3! y_4!} \left(\frac{2+\theta}{4}\right)^{y_1} \left(\frac{1-\theta}{4}\right)^{y_2+y_3} \left(\frac{\theta}{4}\right)^{y_4}$$

Ou

$$L(\theta/Y) \propto \left(\frac{2+\theta}{4}\right)^{y_1} \left(\frac{1-\theta}{4}\right)^{y_2+y_3} \left(\frac{\theta}{4}\right)^{y_4} \rightarrow \text{posteriori observada}$$

Suponha que consideremos $X=(x_1, \dots, x_5)$ como sendo os dados aumentados (completos) onde $y_1 = x_1+x_2$, $y_2=x_3$, $y_3=x_4$ e $y_4=x_5$, com probabilidades $(\frac{1-\theta}{2}, \frac{\theta}{4}, \frac{1-\theta}{4}, \frac{1-\theta}{4}, \frac{\theta}{4})$, de modo que

$$L(\theta/X) \propto \left(\frac{1-\theta}{4}\right)^{x_3+x_4} \left(\frac{\theta}{4}\right)^{x_2+x_5} \rightarrow \text{posteriori aumentado}$$

Podemos simplificar e utilizar

$$L(\theta/Y) \propto (2+\theta)^{y_1} (1-\theta)^{y_2+y_3} \theta^{y_4}$$

E

$$L(\theta/X) \propto \theta^{x_2+x_5} (1-\theta)^{x_3+x_4} \quad (\text{mais simples})$$

A formula (1) fica

$$L(\theta/Y) = \sum_{x_1, x_2} L(\theta/x_1, x_2, 18, 20, 34)$$

Onde a soma é estendida a todos os pares (x_1, x_2) tais que $x_1+x_2=125$, $x_i \geq 0$, $i=1,2$.

ALGORITMO EM:

- 1) tomemos um valor inicial, $\theta^{(0)}$, como estimador de θ .
- 2) Encontremos a esperança condicional de X , dado Y , ($Y=(125, 18, 20, 34)$, $y_1=x_1+x_2$), ou seja, estimemos os dados por suas esperanças condicionais, dado Y e $\theta^{(0)}$.

Passo E:

$$E[x_3/Y, \theta^{(0)}] = 18$$

$$E[x_4/Y, \theta^{(0)}] = 20$$

$$E[x_5/Y, \theta^{(0)}] = 34$$

$$E[x_1/Y, \theta^{(0)}] = E[x_1/x_1+x_2=125, \theta^{(0)}] = x_1^{(0)}$$

$$E[x_2/Y, \theta^{(0)}] = E[x_2/x_1+x_2=125, \theta^{(0)}] = x_2^{(0)}$$

mas, $x_1/x_1+x_2=125 \sim$ binomial, $n=125$,

$$P_1 = \frac{1/2}{(2+\theta^{(0)})/4} = \frac{2}{2+\theta^{(0)}}$$

$$x_2/x_1+x_2 = 125 \sim \text{binomial}, n=125, P_2 = \frac{\theta^{(0)}/4}{(2+\theta^{(0)})/4} = \frac{\theta^{(0)}}{2+\theta^{(0)}}$$

$$\rightarrow x_1^{(0)} = np_1 = \frac{250}{2+\theta^{(0)}} \text{ e } x_2^{(0)} = np_2 = \frac{125\theta^{(0)}}{2+\theta^{(0)}}$$

DADOS LATENTES $\rightarrow X^{(0)} = (x_1^{(0)}, x_2^{(0)}, 18, 20, 34)$: dados completos estimados

3. **O passo M:** consiste em maximizar a verossimilhança dos dados completos $L(\theta/X^{(0)})$.

Temos

$$l(\theta/X^{(0)}) = x_1^{(0)} \log(1/2) + x_2^{(0)} \log(\theta/4) + x_3 \log\left(\frac{1-\theta}{4}\right) + x_4 \log\left(\frac{1-\theta}{4}\right) + x_5 \log(\theta/4)$$

$$l(\theta/X^{(0)}) \propto (x_2^{(0)} + x_5) \log(\theta) + (x_3 + x_4) \log(1-\theta)$$

Derivando em relação a θ , obtemos

$$\frac{dl}{d\theta} = \frac{x_2^{(0)} + x_5}{\theta} - \frac{x_3 + x_4}{1-\theta}$$

$$\Rightarrow \hat{\theta}^{(1)} = \frac{x_2^{(0)} + x_5}{x_2^{(0)} + x_3 + x_4 + x_5} = \frac{x_2^{(0)} + 34}{x_2^{(0)} + 72}$$

De um modo geral, dada a estimativa na iteração (i), $\theta^{(i)}$, estimados os dados latentes por

$$x_1^{(i)} = \frac{250}{2 + \theta^{(i)}}, \quad x_2^{(i)} = \frac{125\theta^{(i)}}{2 + \theta^{(i)}}$$

E atualizamos o estimador de θ por

$$\theta^{(i+1)} = \frac{x_2^{(i)} + 34}{x_2^{(i)} + 72}$$

Se $\theta^{(0)} = 0,5$

Iteração(i)	$\theta^{(i)}$
0	0,5
1	0,60800
2	0,62400
3	0,62648
4	0,62677
5	0,62681
6	0,62682
7	0,62682

$$\Rightarrow \hat{\theta} = 0,62682, \quad \hat{\pi}_1 = \frac{\hat{\theta} + 2}{4} = 0,6567, \quad \hat{\pi}_3 = \hat{\pi}_4 = \frac{1 - \hat{\theta}}{4} = 0,0933, \quad \hat{\pi}_4 = \frac{\hat{\theta}}{4} = 0,1567$$

3. ALGORITMO EM GERAL

Podemos utilizar o algoritmo EM para maximizar $L(\theta/Y)$ ou então a posteriori $P(\theta/Y)$. neste caso, temos a posteriori aumentada $P(\theta/Y,Z) = P(\theta/X)$. neste contexto bayesiano, temos que considerar a densidade

$P(Z/Y, \theta^{(i)})$: distribuição condicional preditora dos dados latentes Z , condicional ao valor atual da moda ou aos dados observados.

No exemplo 2, esta distribuição é a binomial com parâmetros $n = 125$ e $p = \theta^{(i)}/(2 + \theta^{(i)})$.

O algoritmo descrito está em termos da verossimilhança. Para o caso da densidade a posteriori, faz-se as modificações necessárias.

ALGORITMO EM:

1. **passo E**: calculamos

$$Q[\theta, \theta^{(i)}] = E[\ln(\theta/X)/Y, \theta^{(i)}]$$

Ou seja, a esperança condicional da log-verossimilhança aumentada, supondo dados Y e o valor atual $\theta^{(i)}$.

2. **Passo M**: escolhemos o valor $\theta^{(i+1)}$ no espaço paramétrico que maximiza $Q[\theta, \theta^{(i)}]$.

3. itere até convergência, ou seja, até que

$$\|\theta^{(i+1)} - \theta^{(i)}\| \text{ ou } \|Q[\theta, \theta^{(i+1)}] - Q[\theta, \theta^{(i)}]\|$$

sejam suficientemente pequenos.

No caso da posteriori consideramos

$$Q(\theta, \theta^{(i)}) = \int_Z \log p(\theta/Y, Z) p(Z/Y, \theta^{(i)}) dz$$



dist. Cond. Preditor dos dados latentes

EXEMPLO 3: VOLTAMOS AO EXEMPLO DO MODELO GENETICO

$$Q(\theta, \theta^{(i)}) = E[(x_2 + x_5) \log(\theta) + (x_3 + x_4) \log(1 - \theta) / Y, \theta^{(i)}] = \\ = [E(x_2 / Y, \theta^{(i)}) + x_5] \log(\theta) + (x_3 + x_4) \log(1 - \theta)$$

Sabemos que

$$E[x_2 / Y, \theta^{(i)}] = \frac{125\theta^{(i)}}{2 + \theta^{(i)}}$$

Maximizando $Q[\theta, \theta^{(i)}]$, obtemos

$$\theta^{(i+1)} = \frac{E(x_2 / Y, \theta^{(i)}) + x_5}{E(x_2 / Y, \theta^{(i)}) + x_3 + x_4 + x_5}$$

PROPOSIÇÃO 1: seja $l(\theta)$ a verossimilhança dos dados observados. Então

$$l(\theta^{(i+1)} / Y) \geq l(\theta^{(i)} / Y)$$

Toda iteração do algoritmo EM aumenta a log-verossimilhança. O mesmo vale para a densidade a posteriori.

PROPOSIÇÃO 2: suponha que uma sequência de iterações do algoritmo EM satisfaça

- i) $\frac{\partial Q(\theta, \theta^{(i)})}{\partial \theta} \Big|_{\theta = \theta^{(i+1)}} = 0$
- ii) $\theta^{(i)} \rightarrow \theta^*$

então, as iterações convergem para um ponto estacionário de $L(\theta/Y)$.

4. MONTE CARLO EM

No passo E do algoritmo EM, temos que calcular

$$Q(\theta, \theta^{(i)}) = \int_Z \log p(\theta / Y, Z) p(Z / Y, \theta^{(i)}) dz$$

que pode ser complicado. Podemos utilizar MMC para facilitar esse passo. Wei and Tanner (1990)

Algoritmo MCEM para o passo E:

- 1) simule uma amostra iid z_1, z_2, \dots, z_m de $P(Z/Y, \theta^{(i)})$
- 2) calcule $\hat{Q}_{i+1}(\theta) = \frac{1}{m} \sum_{j=1}^m \log P(\theta / z_j, Y)$
- 3) no passo M, \hat{Q} é maximizado para obter $\theta^{(i+1)}$.

Um problema é especificar o valor de m. Uma solução é aumentar o valor de m à medida que o número de iterações cresce e monitorar a convergência, por meio de um gráfico de $\theta^{(i)} \times i$.

EXEMPLO 3: no problema genético, $(x_2 / \theta^{(i)}, Y) \sim \text{binomial}$ com parâmetros $n=125$ e $p = \frac{\theta^{(i)}}{2 + \theta^{(i)}}$. Geramos z_1, z_2, \dots, z_m dessa distribuição e fazemos

$$\hat{E}(x_2 / \theta^{(i)}, Y) = \frac{1}{m} \sum_{i=1}^m z_i = \bar{z}$$

O passo M continua como antes, obtendo-se

$$\theta^{(i+1)} = (\bar{z} + x_5) / ((\bar{z} + x_3 + x_4 + x_5))$$

ALGORITMOS PARA DADOS AUMENTADOS

1. INTRODUÇÃO

Dois algoritmos baseados na consideração de dados latentes. Temos os dados efetivamente observados, Y , e de uma maneira conveniente aumentamos esses dados, introduzindo os dados, Z , chamamos latentes ou não observados, de modo a facilitar o procedimento de cálculo da verossimilhança ou da densidade a posteriori.

O princípio de "aumento dos dados" pode ser enunciado da seguinte forma: "aumentar" ao dados observados Y , com dados latentes Z de tal forma que $P(\theta/y,z)$ ou $L(\theta/y,z)$ sejam simples.

ALGORITMO EM: maximizar a verossimilhança dos dados observados utilizando-se os dados completos $X=\{Y,Z\}$ de maneira conveniente.

ALGORITMO DE DADOS AUMENTAODS: maximizar $P(\theta/y)$ utilizando $P(\theta/y,z)$.

EXEMPLO 1: suponha que se observe um processo periodicamente (por ex., peixes presos em armadilhas) que se acumule em intervalos regulares:

x_1, x_2, \dots, x_7 : quantidade nos dias 1, 2, ..., 7.

$$y_1 = x_1 + x_2$$

$y_2 = x_3 \rightarrow X = (x_1, x_2, \dots, x_7)$: dados completos (o que deveria ter sido observado)

$y_3 = x_4 + x_5 \quad Y = (y_1, y_2, \dots, y_4)$: dados incompletos (o que foi observado)

$$y_4 = x_6 + x_7$$

2. ALGORITMO EM

$X = (x_1, x_2, \dots, x_n)'$ do modelo $f(x/\theta) \rightarrow L(\theta/x)$.

Suponha que não observamos X completamente, mas alguma função de X , digamos $Y=h(X)$. Dizemos que

X : dados completos

$Y=h(X)$: dados incompletos

A **verossimilhança** dos dados observados(incompletos) Y é dada por

$$L(\theta/Y) = \int_{\psi(y)} L(\theta/X) dX \quad (1)$$

Onde $\psi(y)$: parte do espaço amostral ψ de X determinada pela equação $y=h(x)$.

O algoritmo EM (**E**: esperança, **M**: maximização) é um procedimento iterativo segundo o qual encontramos o valor de θ que maximiza a verossimilhança dos dados observados, $L(\theta/Y)$, usando $L(\theta/X)$ de maneira conveniente. "conveniente" significa escolher $L(\theta/X)$ que fornece $L(\theta/Y)$, utilizando (1), de modo a tornar o problema fácil.

EXEMPLO 2: problema genético estudado.

197 animais distribuídos em 4 classes:

$(y_1, y_2, y_3, y_4)'$ segundo as prob. $\frac{\theta+2}{4}$, $\frac{1-\theta}{4}$, $\frac{1-\theta}{4}$, $\frac{\theta}{4}$,

$0 < \theta < 1$.

$Y = (125, 18, 20, 34) = (y_1, y_2, y_3, y_4)'$

A verossimilhança dos dados incompletos, é dada por

$$L(\theta/Y) = \frac{(y_1 + y_2 + y_3 + y_4)!}{y_1! y_2! y_3! y_4!} \left(\frac{2+\theta}{4}\right)^{y_1} \left(\frac{1-\theta}{4}\right)^{y_2+y_3} \left(\frac{\theta}{4}\right)^{y_4}$$

Ou

$$L(\theta/Y) \propto \left(\frac{2+\theta}{4}\right)^{y_1} \left(\frac{1-\theta}{4}\right)^{y_2+y_3} \left(\frac{\theta}{4}\right)^{y_4} \rightarrow \text{posteriori observada}$$

Suponha que consideremos $X=(x_1, \dots, x_5)$ como sendo os dados aumentados (completos) onde $y_1 = x_1+x_2$, $y_2=x_3$, $y_3=x_4$ e $y_4=x_5$, com probabilidades $(\frac{1-\theta}{2}, \frac{\theta}{4}, \frac{1-\theta}{4}, \frac{1-\theta}{4}, \frac{\theta}{4})$, de modo que

$$L(\theta/X) \propto \left(\frac{1-\theta}{4}\right)^{x_3+x_4} \left(\frac{\theta}{4}\right)^{x_2+x_5} \rightarrow \text{posteriori aumentado}$$

Podemos simplificar e utilizar

$$L(\theta/Y) \propto (2+\theta)^{y_1} (1-\theta)^{y_2+y_3} \theta^{y_4}$$

E

$$L(\theta/X) \propto \theta^{x_2+x_5} (1-\theta)^{x_3+x_4} \quad (\text{mais simples})$$

A formula (1) fica

$$L(\theta/Y) = \sum_{x_1, x_2} L(\theta/x_1, x_2, 18, 20, 34)$$

Onde a soma é estendida a todos os pares (x_1, x_2) tais que $x_1+x_2=125$, $x_i \geq 0$, $i=1,2$.

ALGORITMO EM:

- 1) tomemos um valor inicial, $\theta^{(0)}$, como estimador de θ .
- 2) Encontremos a esperança condicional de X , dado Y , ($Y=(125, 18, 20, 34)$, $y_1=x_1+x_2$), ou seja, estimemos os dados por suas esperanças condicionais, dado Y e $\theta^{(0)}$.

Passo E:

$$E[x_3/Y, \theta^{(0)}] = 18$$

$$E[x_4/Y, \theta^{(0)}] = 20$$

$$E[x_5/Y, \theta^{(0)}] = 34$$

$$E[x_1/Y, \theta^{(0)}] = E[x_1/x_1+x_2=125, \theta^{(0)}] = x_1^{(0)}$$

$$E[x_2/Y, \theta^{(0)}] = E[x_2/x_1+x_2=125, \theta^{(0)}] = x_2^{(0)}$$

mas, $x_1/x_1+x_2=125 \sim$ binomial, $n=125$,

$$P_1 = \frac{1/2}{(2+\theta^{(0)})/4} = \frac{2}{2+\theta^{(0)}}$$

$$x_2/x_1+x_2 = 125 \sim \text{binomial}, n=125, P_2 = \frac{\theta^{(0)}/4}{(2+\theta^{(0)})/4} = \frac{\theta^{(0)}}{2+\theta^{(0)}}$$

$$\rightarrow x_1^{(0)} = np_1 = \frac{250}{2+\theta^{(0)}} \text{ e } x_2^{(0)} = np_2 = \frac{125\theta^{(0)}}{2+\theta^{(0)}}$$

DADOS LATENTES $\rightarrow X^{(0)} = (x_1^{(0)}, x_2^{(0)}, 18, 20, 34)$: dados completos estimados

3. **O passo M:** consiste em maximizar a verossimilhança dos dados completos $L(\theta/X^{(0)})$.

Temos

$$l(\theta/X^{(0)}) = x_1^{(0)} \log(1/2) + x_2^{(0)} \log(\theta/4) + x_3 \log\left(\frac{1-\theta}{4}\right) + x_4 \log\left(\frac{1-\theta}{4}\right) + x_5 \log(\theta/4)$$

$$l(\theta/X^{(0)}) \propto (x_2^{(0)} + x_5) \log(\theta) + (x_3 + x_4) \log(1-\theta)$$

Derivando em relação a θ , obtemos

$$\frac{dl}{d\theta} = \frac{x_2^{(0)} + x_5}{\theta} - \frac{x_3 + x_4}{1-\theta}$$

$$\Rightarrow \hat{\theta}^{(1)} = \frac{x_2^{(0)} + x_5}{x_2^{(0)} + x_3 + x_4 + x_5} = \frac{x_2^{(0)} + 34}{x_2^{(0)} + 72}$$

De um modo geral, dada a estimativa na iteração (i), $\theta^{(i)}$, estimados os dados latentes por

$$x_1^{(i)} = \frac{250}{2 + \theta^{(i)}}, \quad x_2^{(i)} = \frac{125\theta^{(i)}}{2 + \theta^{(i)}}$$

E atualizamos o estimador de θ por

$$\theta^{(i+1)} = \frac{x_2^{(i)} + 34}{x_2^{(i)} + 72}$$

Se $\theta^{(0)} = 0,5$

Iteração(i)	$\theta^{(i)}$
0	0,5
1	0,60800
2	0,62400
3	0,62648
4	0,62677
5	0,62681
6	0,62682
7	0,62682

$$\Rightarrow \hat{\theta} = 0,62682, \quad \hat{\pi}_1 = \frac{\hat{\theta} + 2}{4} = 0,6567, \quad \hat{\pi}_3 = \hat{\pi}_4 = \frac{1 - \hat{\theta}}{4} = 0,0933, \quad \hat{\pi}_4 = \frac{\hat{\theta}}{4} = 0,1567$$

3. ALGORITMO EM GERAL

Podemos utilizar o algoritmo EM para maximizar $L(\theta/Y)$ ou então a posteriori $P(\theta/Y)$. neste caso, temos a posteriori aumentada $P(\theta/Y,Z) = P(\theta/X)$. neste contexto bayesiano, temos que considerar a densidade

$P(Z/Y, \theta^{(i)})$: distribuição condicional preditora dos dados latentes Z , condicional ao valor atual da moda ou aos dados observados.

No exemplo 2, esta distribuição é a binomial com parâmetros $n = 125$ e $p = \theta^{(i)}/(2 + \theta^{(i)})$.

O algoritmo descrito está em termos da verossimilhança. Para o caso da densidade a posteriori, faz-se as modificações necessárias.

ALGORITMO EM:

1. **passo E**: calculamos

$$Q[\theta, \theta^{(i)}] = E[\ln(\theta/X)/Y, \theta^{(i)}]$$

Ou seja, a esperança condicional da log-verossimilhança aumentada, supondo dados Y e o valor atual $\theta^{(i)}$.

2. **Passo M**: escolhemos o valor $\theta^{(i+1)}$ no espaço paramétrico que maximiza $Q[\theta, \theta^{(i)}]$.

3. itere até convergência, ou seja, até que

$$\|\theta^{(i+1)} - \theta^{(i)}\| \text{ ou } \|Q[\theta, \theta^{(i+1)}] - Q[\theta, \theta^{(i)}]\|$$

sejam suficientemente pequenos.

No caso da posteriori consideramos

$$Q(\theta, \theta^{(i)}) = \int_Z \log p(\theta/Y, Z) p(Z/Y, \theta^{(i)}) dz$$



dist. Cond. Preditor dos dados latentes

EXEMPLO 3: VOLTAMOS AO EXEMPLO DO MODELO GENETICO

$$Q(\theta, \theta^{(i)}) = E[(x_2 + x_5) \log(\theta) + (x_3 + x_4) \log(1 - \theta) / Y, \theta^{(i)}] = \\ = [E(x_2 / Y, \theta^{(i)}) + x_5] \log(\theta) + (x_3 + x_4) \log(1 - \theta)$$

Sabemos que

$$E[x_2 / Y, \theta^{(i)}] = \frac{125\theta^{(i)}}{2 + \theta^{(i)}}$$

Maximizando $Q[\theta, \theta^{(i)}]$, obtemos

$$\theta^{(i+1)} = \frac{E(x_2 / Y, \theta^{(i)}) + x_5}{E(x_2 / Y, \theta^{(i)}) + x_3 + x_4 + x_5}$$

PROPOSIÇÃO 1: seja $l(\theta)$ a verossimilhança dos dados observados. Então

$$l(\theta^{(i+1)} / Y) \geq l(\theta^{(i)} / Y)$$

Toda iteração do algoritmo EM aumenta a log-verossimilhança. O mesmo vale para a densidade a posteriori.

PROPOSIÇÃO 2: suponha que uma sequência de iterações do algoritmo EM satisfaça

- i) $\frac{\partial Q(\theta, \theta^{(i)})}{\partial \theta} \Big|_{\theta=\theta^{(i+1)}} = 0$
- ii) $\theta^{(i)} \rightarrow \theta^*$

então, as iterações convergem para um ponto estacionário de $L(\theta/Y)$.

4. MONTE CARLO EM

No passo E do algoritmo EM, temos que calcular

$$Q(\theta, \theta^{(i)}) = \int_Z \log p(\theta/Y, Z) p(Z/Y, \theta^{(i)}) dz$$

que pode ser complicado. Podemos utilizar MMC para facilitar esse passo. Wei and Tanner (1990)

Algoritmo MCEM para o passo E:

- 1) simule uma amostra iid z_1, z_2, \dots, z_m de $P(Z/Y, \theta^{(i)})$
- 2) calcule $\hat{Q}_{i+1}(\theta) = \frac{1}{m} \sum_{j=1}^m \log P(\theta/z_j, Y)$
- 3) no passo M, \hat{Q} é maximizado para obter $\theta^{(i+1)}$.

Um problema é especificar o valor de m . Uma solução é aumentar o valor de m à medida que o número de iterações cresce e monitorar a convergência, por meio de um gráfico de $\theta^{(i)} \times i$.

EXEMPLO 3: no problema genético, $(x_2/\theta^{(i)}, Y) \sim \text{binomial}$ com parâmetros $n=125$ e $p = \frac{\theta^{(i)}}{2 + \theta^{(i)}}$. Geramos z_1, z_2, \dots, z_m dessa distribuição e fazemos

$$\hat{E}(x_2 / \theta^{(i)}, Y) = \frac{1}{m} \sum_{i=1}^m z_i = \bar{z}$$

O passo M continua como antes, obtendo-se

$$\theta^{(i+1)} = (\bar{z} + x_5) / ((\bar{z} + x_3 + x_4 + x_5))$$

5. CÁLCULO DOS ERROS PADRÕES

ALGORITMO EM → Calcula a moda da distribuição à posteriori: $P(\theta/Y)$ ou da fv $L((\theta/Y)$

Para obter erros padrões devemos calcular a matriz Lessiana. Há 3 formas possíveis:

a) cálculo direto ou numérico

obtido o **EMV** $\hat{\theta}$, podemos calcular as derivadas segundas de $\log L((\theta/Y)$ ou de $\log P((\theta/Y)$, no ponto $\hat{\theta}$.

$$\text{Var}_{\theta_0}(\hat{\theta}) \rightarrow I(\theta_0)^{-1}$$

$I(\theta) = -E_{\theta}[\ddot{l}(\theta/Y)]$: **informação de Fisher**

Na prática, isto pode ser difícil e um enfoque alternativo é calcular as derivadas numericamente.

b) método de Louis

sabemos que

$$\log[P(\theta/Y)] = \log[p(\theta/Y, Z)] - \log[P(Z/\theta, Y)] + \log P(Z/Y)$$

$$\frac{-\partial^2 \log[p(\theta/Y)]}{\partial \theta_i \partial \theta_j} = \frac{-\partial^2 \log[P(\theta/Y, Z)]}{\partial \theta_i \partial \theta_j} + \frac{\partial^2 \log[P(Z/Y, \theta)]}{\partial \theta_i \partial \theta_j}$$

Integrando ambos os lados com respeito a $P(Z/Y, \theta)$, obtemos

$$\frac{-\partial^2 \log[p(\theta/Y)]}{\partial \theta_i \partial \theta_j} = \frac{-\partial^2}{\partial \theta_i \partial \theta_j} Q(\theta, \theta^{(i)})|_{\theta^{(i)}=\theta} + \frac{\partial^2}{\partial \theta_i \partial \theta_j} H(\theta, \theta^{(i)})|_{\theta^{(i)}=\theta}$$

Esta identidade constitui o princípio da informação faltante:

Informação observada =
= informação completa - informação faltante

RESULTADO: $\frac{\partial^2}{\partial \theta^2} H = \text{var} \left[\frac{\partial \log P(\theta/Y, Z)}{\partial \theta} \right]$: informação faltante

Utilizando esse resultado e a expressão acima, podemos obter o erro padrão de $\hat{\theta}$.

EXEMPLO 5: voltamos ao problema genético

$$P(\theta/Y, Z) \propto \theta^{x_2+x_5} (1-\theta)^{x_3+x_4}$$

$$\frac{\partial \log P(\theta/Y, Z)}{\partial \theta} = \frac{x_2 + x_5}{\theta} - \frac{x_3 + x_4}{1-\theta}$$

inf. completa

$$\Rightarrow \frac{-\partial^2 Q}{\partial \theta^2} \Big|_{\hat{\theta}} = \frac{E(x_2/Y, \hat{\theta}) + x_5}{\hat{\theta}^2} + \frac{x_3 + x_4}{1-\hat{\theta}} = \frac{29,83 + 34}{(0,6268)^2} + \frac{18 + 20}{1 - (0,6268)^2} = 435,3$$

informação faltante:

→

$$\frac{\partial^2}{\partial \theta^2} H = \text{var} \left[\frac{\partial \log P(\theta/Y, Z)}{\partial \theta} \right] = \frac{\text{var}(X_2 / \hat{\theta})}{\hat{\theta}^2} = \frac{np(1-p)}{\hat{\theta}^2} = \frac{125x \frac{\hat{\theta}}{2+\hat{\theta}} x \frac{2}{2+\hat{\theta}}}{\hat{\theta}^2} = 57,8$$

Informação observada:

$$\frac{-\partial^2 \log P(\theta/Y)}{\partial \theta^2} = 435,3 - 57,8 = 377,5$$

$$\Rightarrow ep(\hat{\theta}) = \sqrt{\frac{1}{377,5}} = 0,05$$

c) simulação

o cálculo da **informação completa** pode ser complicado

$$-\int_z \frac{\partial^2 \log P(\theta/Y, Z)}{\partial \theta^2} P(Z/\hat{\theta}/Y) dZ : \text{informação completa}$$

Se pudemos amostrar da densidade $P(Z/\theta, Y)$, a integral pode ser aproximada por

$$\frac{1}{m} \sum_{j=1}^m \frac{\partial^2 \log P(\theta/Y, Z_j)}{\partial \theta^2} : \text{informação completa simulada,}$$

Z: valor simulado, $z_1, z_2, \dots, z_m \sim \text{iid } P(Z/\hat{\theta}, Y)$

De modo análogo, podemos aproximar a **informação faltante**:

$$\frac{\partial^2}{\partial \theta^2} H = \text{var} \left[\frac{\partial \log P(\theta/Y, Z)}{\partial \theta} \right] \text{ por}$$

$$\frac{1}{m} \sum_{j=1}^m \left(\frac{\partial \log P(\theta/Y, z_j)}{\partial \theta} \right)^2 - \left[\frac{1}{m} \sum_{i=1}^m \frac{\partial \log P(\theta/Y, z_j)}{\partial \theta} \right]^2 : \text{informação faltante simulada}$$

No exemplo genético,

$$(Z/\hat{\theta}, Y) \sim \text{binomial}(125, \frac{\hat{\theta}}{2 + \hat{\theta}}) \text{ com } \hat{\theta} \rightarrow 0,6268$$

6. ALGORITMO DE DADOS AUMENTADOS

O algoritmo EM utiliza a simplicidade da verossimilhança (ou densidade a posteriori) dos dados aumentados. No algoritmo de dados aumentados (ADA), em vez de obter o máximo dessas funções, o objetivo é obter a verossimilhança ou distribuição a posteriori, a fim de obter outras informações como intervalos de confiança (ou credibilidade). Trabalharemos, aqui, com a distribuição a posteriori. A idéia é obter uma estimativa de $P(\theta/Y)$, baseada na distribuição aumentada $P((\theta/Y, Z)$.

O ADA é motivado por duas identidades:

$$P(\theta/Y) = \int_z P(\theta/Y, Z)P(Z/Y)dz : \text{identidade da posteriori}$$

↓

$P(\theta/Y)$: densidade da posteriori de θ

$P(\theta/Y, Z)$: posteriori aumentada

$P(Z/Y)$: densidade preditiva dos dados latentes dado Y

$$P(Z/Y) = \int_{\theta} P(z/\phi, Y)P(\phi/Y)d\phi : \text{identidade da preditora}$$

$P(Z/\Phi, Y)$: preditora dos dados latentes

O ADA é um algoritmo iterativo entre essas duas identidades, aproximando sucessivamente a densidade a posteriori.

ALGORITMO ADA:

[1] simule z_1, z_2, \dots, z_m da estimativa atual $P(Z/Y)$

[2] atualize a estimativa $P(\theta/Y)$ por meio de

$$\frac{1}{m} \sum_{j=1}^m P(\theta/Y, Z_j)$$

[3] itera.

No passo precisamos simular da preditora $P(Z/Y)$. Pela identidade da preditora: $P(Z/Y) = \int_{\theta} P(z/\phi, Y)P(\phi/Y)d\phi$, ela é

uma mistura de preditoras aumentadas em relação à posteriori observada, esse passo pode ser implementado por meio da iteração:

[1'] simule θ^* da estimativa atual $P(\theta/Y)$

[2'] amostre z de $P(z/\theta^*, Y)$

Por sua vez, o passo [1'], simulação da posteriori observada atual, é realizado selecionando-se j aleatoriamente dos inteiros $1, 2, \dots, m$ e então simulando de $P(\theta/z_j, Y)$, dada a forma discreta da estimativa de $P(\theta/Y)$ em [2] (no passo [2] do ADA).

Comparando esse algoritmo com o EM, temos:

Substituímos os passos E e M pelos passos que chamamos S e I, onde,

S: estamos simulando dos dados latentes da estimativa atual da preditora.

I: depois integramos para obter a posteriori.

Podemos então chamar o ADA de algoritmo SI (S de simulação e I de integração).

EXEMPLO 6: continuando o exemplo do problema genético

Posteriori aumentada

$$P(\theta/X) \propto \theta^{x_2+x_5} (1-\theta)^{x_3+x_4} \sim \text{Beta}(x_2+x_5+1, x_3+x_4+1)$$

$$(X_2/Y, \theta) \sim \text{Binomial}(125, \theta/(\theta+2)), \text{ onde } Z = X_2$$

↓
preditora aumentada

ALGORITMO SI:

[1] simule x_2^1, \dots, x_2^m da estimativa atual de $P(X_2/Y)$

[2] atualize a estimativa de $P(\theta/Y)$ por meio de

$$\frac{1}{m} \sum_{j=1}^m \text{Beta}(\alpha_j, \beta_j)(\theta)$$

Com $\alpha_j = x_2^j + x_5 + 1$ e $\beta_j = x_3 + x_4 + 1$

O passo [1] do algoritmo consiste em repetir m vezes:

[1'] gere j uniformemente de 1, 2, ..., m

[2'] simule θ^* da Beta(α_j, β_j)

[3'] simule x da binomial(125, $\theta^*/(2 + \theta^*)$)