

Algoritmo EM (Expectation - Maximization)

Este algoritmo obtiene soluciones que convergen al estimador máximo verosímil, se basa en la idea de reemplazar el problema de maximizar la verosimilitud cuando esto es difícil por una sucesión de maximizaciones fáciles, y convergen a la solución del problema original.

El algoritmo EM considera dos problemas de verosimilitud diferentes, el problema de datos incompletos (que es el problema que estamos interesados en resolver), y el problema de datos completos, que es el problema que resolveremos.

Ejemplo: Observamos X_1, \dots, X_n e Y_1, \dots, Y_n los cuales son mutuamente independientes $X_i \sim \text{Poisson}(\lambda_i)$ y $Y_i \sim \text{Poisson}(\beta \lambda_i)$. Este modelo puede ser por ejemplo la incidencia de una enfermedad Y_i donde la tasa es una función de un efecto promedio β , un factor adicional al Z_i [por ejemplo el nivel de salud en el área i]. Z_i no se observa pero tenemos información de este a partir de X_i .

La función de probabilidad conjunta de X e Y es

$$f((x_1, y_1), (x_2, y_2), \dots, (x_n, y_n) | \beta, z_1, \dots, z_n) = \prod_{i=1}^n \frac{e^{-\beta z_i} (\beta z_i)^{y_i}}{y_i!} \frac{e^{-z_i} z_i^{x_i}}{x_i!} \prod_{i=1}^n \text{Poisson}(\lambda_i)$$

$$= \prod_{i=1}^n \frac{e^{-\beta z_i} (\beta z_i)^{y_i}}{y_i!} \frac{e^{-z_i} z_i^{x_i}}{x_i!} \left. \vphantom{\prod_{i=1}^n} \right\} \begin{array}{l} \text{Poisson } (\lambda) \\ P(X=k) = e^{-\lambda} \frac{\lambda^k}{k!} \end{array}$$

Si resolvemos el problema maximizando la expresión obtenida se obtiene (Ver más abajo)

$$\hat{\beta} = \frac{\sum_{i=1}^n y_i}{\sum_{i=1}^n x_i} \quad \gamma_j = \frac{x_j + y_j}{\hat{\beta} + 1} \quad j=1, 2, \dots, n$$

Se ha planteado el problema en los datos completos $(x_1, y_1), \dots, (x_n, y_n)$.

Los datos perdidos hacen la estimación más difícil, por ejemplo supongamos que x_1 es missing. Podemos descartar y_1 y trabajar con una muestra de tamaño $n-1$ o se ignoramos la información de y_1 .

Pero sabemos que si pudiéramos usar esa información podemos mejorar nuestros estimadores.

La función de probabilidad cuando x_1 es missing es

$$\sum_{x_1=0}^{\infty} f((x_1, y_1), (x_2, y_2), \dots, (x_n, y_n) | \beta, z_1, z_2, \dots, z_n)$$

este es el problema basado en los datos incompletos. Esta es la verosimilitud que queremos maximizar.

En general $Y = (y_1, \dots, y_n)$ son los datos incompletos y

$X^0 = (x_1, \dots, x_n)$ son los datos aumentados y entonces (Y, X) son los datos completos

Consideremos las densidades $g(\cdot|\theta)$ de Y y $f(\cdot|\theta)$ de (Y, X) . Se cumple que

$$g(y|\theta) = \int f(y, x|\theta) dx$$

(en el caso discreto la suma reemplaza a la integral)

O sea $L(\theta|y) = g(y|\theta)$ será la verosimilitud para los datos incompletos y $L(\theta|y, x) = f(y, x|\theta)$ la verosimilitud para los datos completos.

En nuestro caso la verosimilitud para datos incompletos es:

$$\begin{aligned} L(\beta, z_1, z_2, \dots, z_n | j_1, (x_2, j_2), \dots, (x_n, j_n)) \\ = \prod_{i=1}^n \frac{e^{-\beta z_i} (\beta z_i)^{j_i}}{j_i!} \prod_{i=2}^n \frac{e^{-z_i} (z_i)^{x_i}}{x_i!} \end{aligned}$$

Resolviendo se obtiene $\hat{\beta} = \frac{\sum_{i=1}^n j_i}{\sum_{i=1}^n \hat{z}_i}$

$$j_1 = \hat{z}_1 \hat{\beta}$$

$$x_j + j_j = \hat{z}_j (\hat{\beta} + 1) \quad j=2, 3, \dots, n$$

Vemos este problema resuelto por el algoritmo EM
 El algoritmo EM nos permite maximizar $L(\theta|y)$
 trabajando solo con $L(\theta|y, x)$ y la función de
 densidad condicional de X dado Y, θ $h(x|\theta, y)$

$$L(\theta|y, x) = f(y, x|\theta)$$

$$h(x|\theta, y) = \frac{f(y, x|\theta)}{g(y|\theta)}$$

$$\log L(\theta|y) = \log g(y|\theta) = \log \frac{f(y, x|\theta)}{h(x|\theta, y)} =$$

$$= \log f(y, x|\theta) - \log h(x|\theta, y) =$$

$$= \log L(\theta|y, x) - \log h(x|\theta, y)$$

Como x no es observado reemplazamos el lado
 derecho de la igualdad por su esperanza
 bajo $h(x|\theta', y)$ creando una nueva identidad

$$\log L(\theta|y) = E(\log L(\theta|y, x) | \theta', y) - E(\log h(x|\theta, y) | \theta', y)$$

A partir de un valor inicial $\theta^{(0)}$ creamos una
 sucesión $\theta^{(r)}$ como:

$$(\ast \ast \ast) \Theta^{(r+1)} = \underset{\Theta}{\operatorname{argmax}} E(\log L(\Theta | y, x) | \Theta^{(r)}, y)$$

En el algoritmo el "paso E" calcula el valor esperado del logaritmo de la verosimilitud y el "paso M" encuentra el máximo.

En nuestro ejemplo (x, y) notas a los datos completos y $(x_{(-1)}, y)$ notas a los datos incompletos.

$$\text{obs } (x_{(-1)}, y) = (y_1, (x_2, y_2), \dots, (x_n, y_n))$$

$$E(\log L(\beta, z_1, z_2, \dots, z_n | (x, y) | z^{(r)}, (x_{(-1)}, y))) =$$

$$= \sum_{x_1=0}^{+\infty} \log \left(\prod_{i=1}^n \frac{e^{-\beta z_i} (\beta z_i)^{y_i}}{y_i!} \cdot \frac{e^{-z_i} z_i^{x_i}}{x_i!} \right) \frac{e^{-z_1^{(r)}} (z_1^{(r)})^{x_1}}{x_1!}$$

$$= \sum_{i=1}^n [-\beta z_i + y_i (\log \beta + \log z_i) - \log y_i!] +$$

$$+ \sum_{i=2}^n [-z_i + x_i \log z_i - \log x_i!] +$$

$$+ \sum_{x_1=0}^{+\infty} [-z_1 + x_1 \log z_1 - \log x_1!] \frac{e^{-z_1^{(r)}} (z_1^{(r)})^{x_1}}{x_1!} =$$

$$\left(\sum_{i=1}^n [-\beta z_i + y_i (\log \beta + \log z_i)] + \sum_{i=2}^n [-z_i + x_i \log z_i] \right)$$

$$\begin{aligned}
&= \left(\sum_{i=1}^n [-\beta z_i + j_i (\log \beta + \log z_i)] + \sum_{i=2}^n [-z_i + x_i \log z_i] \right. \\
&\quad \left. + \sum_{x_1=0}^{\infty} [-z_1 + x_1 \log z_1] \frac{e^{-z_1^{(r)}} (z_1^{(r)})^{x_1}}{x_1!} \right) - \\
&\quad - \underbrace{\left(\sum_{i=1}^n \log j_i! + \sum_{i=1}^n \log x_i! + \sum_{x_1=0}^{\infty} \log x_1! \frac{e^{-z_1^{(r)}} (z_1^{(r)})^{x_1}}{x_1!} \right)}_{(*)}
\end{aligned}$$

(*) no depende de β , z_i luego la podemos despreciar en la optimización.

Ademas
$$\sum_{x_1=0}^{+\infty} [-z_1 + x_1 \log z_1] \frac{e^{-z_1^{(r)}} (z_1^{(r)})^{x_1}}{x_1!} =$$

$$= -z_1 \underbrace{\sum_{x_1=0}^{+\infty} \frac{e^{-z_1^{(r)}} (z_1^{(r)})^{x_1}}{x_1!}}_1 + \log z_1 \underbrace{\sum_{x_1=0}^{\infty} x_1 \frac{e^{-z_1^{(r)}} (z_1^{(r)})^{x_1}}{x_1!}}_{z_1^{(r)}} =$$

es la esperanza de una Poisson.

$$X \sim P(\lambda) \Rightarrow E(X) = \lambda$$

$$= -z_1 + z_1^{(r)} \log z_1$$

entonces el valor esperado de la verosimilitud de los datos completos es

$$\sum_{i=1}^n [-\beta z_i + y_i (\log \beta + \log z_i)] + \sum_{i=2}^n [-z_i + x_i \log z_i] + (-z_1 + z_1^{(r)} \log z_1).$$

o sea este valor esperado es igual a la verosimilitud de los datos completos con la excepción de que x_1 se reemplaza por $z_1^{(r)}$ luego

$$\hat{\beta}^{(r+1)} = \frac{\sum_{i=1}^n d_i}{z_1^{(r)} + \sum_{i=2}^n x_i}$$

$$\hat{z}_1^{(r+1)} = \frac{\hat{z}_1^{(r)} + d_1}{\hat{\beta}^{(r+1)} + 1}$$

$$\hat{z}_j^{(r+1)} = \frac{x_j + d_j}{\hat{\beta}^{(r+1)} + 1} \quad j = 2, 3, \dots$$

El paso E resulta pues sustituir $\hat{z}_1^{(r)}$ por x_1 y el paso M es el cálculo de los estimadores en la iteración r . $(\hat{\beta}^{(r)}, \hat{z}_1^{(r)}, \hat{z}_2^{(r)}, \dots, \hat{z}_n^{(r)})$

La prueba de que estos estimadores convergen a los estimadores de máxima verosimilitud no la daremos solo enunciaremos el siguiente teorema

Teorema 45: (Sucesión EM monótona)

La sucesión $\{\hat{\theta}^{(r)}\}$ definida por (***) cumple

$$L(\hat{\theta}^{(r+1)} | y) \geq L(\hat{\theta}^{(r)} | y)$$

con igualdad si y solo si dos iteraciones sucesivas obtienen el mismo valor del máximo del valor esperado de la verosimilitud de los datos completos o sea

$$E(\log L(\hat{\theta}^{(r+1)} | y, X) | \hat{\theta}^{(r)}, y) = E(\log L(\hat{\theta}^{(r)} | y, X) | \hat{\theta}^{(r)}, y)$$

Solución del primer problema

$$L(\beta, z_1, \dots, z_n | (x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)) =$$

$$= \prod_{i=1}^n \frac{e^{-\beta z_i} (\beta z_i)^{y_i}}{y_i!} \frac{e^{-z_i} z_i^{x_i}}{x_i!}$$

$$\log L = \sum_{i=1}^n \left[(-\beta z_i) + y_i \log \beta z_i + \log y_i! + (-z_i) + x_i \log z_i - \log x_i! \right]$$

$$\frac{\partial \log L}{\partial \beta} = \sum_{i=1}^n \left[(-z_i) + y_i \frac{z_i}{\beta z_i} \right] = 0 \quad (1)$$

$$\frac{\partial \log L}{\partial z_i} = -\beta + y_i \frac{\beta}{\beta z_i} - 1 + \frac{x_i}{z_i} = 0 \quad \forall i \text{ (ecuaciones)}$$

$$\text{de (1)} \quad \frac{1}{\beta} \sum_{i=1}^n \delta_i = \sum_{i=1}^n z_i \Rightarrow \beta = \frac{\sum_{i=1}^n \delta_i}{\sum_{i=1}^n z_i} \quad (2)$$

$$\text{Si tenemos } \frac{y_i + x_i}{z_i} = 1 + \beta \Rightarrow z_i = \frac{y_i + x_i}{1 + \beta}$$

$$\text{o sea } \sum_{i=1}^n z_i = \frac{\sum_{i=1}^n (y_i + x_i)}{1 + \beta}$$

$$\beta = \frac{\sum_{i=1}^n \delta_i}{\sum_{i=1}^n (y_i + x_i)} \cdot (1 + \beta) \Rightarrow \text{de donde}$$

$$\beta \left(1 - \frac{\sum_{i=1}^n \delta_i}{\sum_{i=1}^n (y_i + x_i)} \right) = \frac{\sum_{i=1}^n \delta_i}{\sum_{i=1}^n (y_i + x_i)}$$

$$\hat{\beta} = \frac{\sum_{i=1}^n \delta_i}{\sum_{i=1}^n x_i}$$

$$\hat{z}_i = \frac{y_i + x_i}{1 + \hat{\beta}} \quad \text{si}$$