

EM 算法简介

chwang@microsoft.com

注意：这是一个非正式的简介，所以没有列出相关的参考文献，以后我会陆续完善。写 EM 简介的文章很多，我这里希望能对初学者有所帮助。水平有限，如有错误，敬请指正。

Expectation-Maximization (EM) 算法是一个在含有隐含变量的模型中常用的算法，最常见的是用于高斯混合模型 (Mixtures of Gaussians)，但 EM 算法的应用决不仅仅限于此。

假设我们要估计联合概率密度 $p(x, y|\Phi)$ ，其中 x 为可以观测的变量， y 为隐含变量， Φ 为参数。令 $\{X, Y\} = \{(x_1, y_1), \dots, (x_N, y_N)\}$ 。 $(x_i, y_i), i \in \{1, 2, \dots, N\}$ 是相互独立的。给定 X ，考虑 Φ 的最大似然估计 (Maximum Likelihood)，也就是最大化下面式子：

$$\mathcal{L}(\Phi|X) = \log \prod_i p(x_i|\Phi) = \sum_i \log p(x_i|\Phi) = \sum_i \log \sum_{y_i} p(x_i, y_i|\Phi).$$

写的更一般一些，可以为：

$$\mathcal{L}(\Phi|X) = \log p(X|\Phi) = \log \sum_Y p(X, Y|\Phi). \text{ 如果 } Y \text{ 是连续变量, } \mathcal{L}(\Phi|X) = \log \int p(X, Y|\Phi) dY$$

基本的 EM 算法：

假设 Y 可观测，那么 $\mathcal{L}(\Phi|X, Y) = \log p(X, Y|\Phi)$ ，通常来说比较容易求解，特别是如果 $p(X, Y|\Phi)$ 是指数族的情况下。

定义 Q 函数: $Q(\Phi, \Phi^{old}) = E_{p(Y|X, \Phi^{old})}[\mathcal{L}(\Phi|X, Y)]$

E-step : Compute $p(Y|X, \Phi^{old})$

M-step: $\Phi^{new} = \operatorname{argmax}_{\Phi} Q(\Phi, \Phi^{old})$

可以证明每次 EM 都可以使得 $\mathcal{L}(\Phi|X)$ 增加，保证收敛到局部极大值。

上述的 EM 算法虽然描述简单，但不是很直观，下面从另外一个角度来导出 EM 算法。

从优化的角度导出的 EM 算法：

首先介绍 Jensen 不等式：

假设 $f(x)$ 为凸函数 (对于凹函数，不等号方向相反)，(对于二阶可导的情况，可以考虑证明 Hessian 矩阵是非负定的，一维情况 $f''(x) \geq 0$)，对于随机变量 X ，有

$$E[f(X)] \geq f(EX)$$

恒成立，等号成立当且仅当 $X = EX$ ，以概率 1 成立 (X 是常数)。如图 1 所示。




图 1. 凸函数

很容易验证 $\log(x)$ 是凹函数。由于直接优化 $\mathcal{L}(\Phi|X) = \log p(X|\Phi) = \log \sum_Y p(X, Y|\Phi)$ 很难，考虑 $\mathcal{L}(\Phi|X)$ 的下界，假设 $q(Y)$ 为任意概率密度：

$$\mathcal{L}(\Phi|X) = \log \sum_Y p(X, Y|\Phi) = \log \sum_Y q(Y) \frac{p(X, Y|\Phi)}{q(Y)} = \log E_{q(Y)} \left[\frac{p(X, Y|\Phi)}{q(Y)} \right]$$

由 Jensen 不等式:

$$\log E_{q(Y)} \left[\frac{p(X, Y|\Phi)}{q(Y)} \right] \geq E_{q(Y)} \left[\log \frac{p(X, Y|\Phi)}{q(Y)} \right]$$

等号成立当且仅当 $\frac{p(X, Y|\Phi)}{q(Y)} = E_{q(Y)} \left[\frac{p(X, Y|\Phi)}{q(Y)} \right] = p(X|\Phi) = \text{constant}$ ，所以有 $q(Y) = p(Y|X, \Phi)$ 。可见，这就是在基本 EM 算法中的 E-step。

而 M-step 则变为:

$$\Phi^{\text{new}} = \operatorname{argmax}_{\Phi^*} \log E_{q(Y)} \left[\frac{p(X, Y|\Phi^*)}{q(Y)} \right] = \operatorname{argmax}_{\Phi^*} E_{q(Y)} \left[\log \frac{p(X, Y|\Phi^*)}{q(Y)} \right]$$

总结，考虑最大化 $\mathcal{L}(\Phi|X)$ 下界 $E_{q(Y)} \left[\log \frac{p(X, Y|\Phi)}{q(Y)} \right] = \sum_Y q(Y) \log \frac{p(X, Y|\Phi)}{q(Y)}$ 的问题，从而解决了最大化 $\mathcal{L}(\Phi|X)$ 的问题。利用 Jensen 也很容易证明 $\mathcal{L}(\Phi|X)$ 是递增的。假设 Φ^n, Φ^{n+1} 为迭代第 $n, n+1$ 的值，并且 $q^n(Y) = p(Y|X, \Phi^n)$ 有：

$$\mathcal{L}(\Phi^{n+1}|X) = \log E_{q^{n+1}(Y)} \left[\frac{p(X, Y|\Phi^{n+1})}{q^{n+1}(Y)} \right]$$

$$\geq E_{q^{n+1}(Y)} \left[\log \frac{p(X, Y|\Phi^{n+1})}{q^{n+1}(Y)} \right]$$

$$\geq E_{q^n(Y)} \left[\log \frac{p(X, Y|\Phi^n)}{q^n(Y)} \right]$$

$$= \mathcal{L}(\Phi^n|X)$$

上式中第一个不等式是由于 Jensen 不等式，第二个是由于 M-step 求最大的性质。

有些时候， $q(Y) = p(Y|X, \Phi)$ 也不是能够显示的计算出来的，这个时候最大化 $\mathcal{L}(\Phi|X)$ 就显得相当困难。这个时候，可以考虑不一定保证 Jensen 不等式一定取等号。如果给定 $q(Y)$ 某种形式，就得到 Variational EM 算法。

To be continued ...