

高斯混合模型的 EM 算法推导

赖泽强

2021 年 1 月 12 日

1 高斯混合模型

高斯混合模型尝试用多个高斯分布对输入数据建模。我们假设模型符合一个联合概率分布

$$p(x^{(i)}, z^{(i)}) = p(x^{(i)}|z^{(i)})p(z^{(i)}) \quad (1)$$

其中 z 服从多项分布 $z^{(i)} \sim \text{Multinomial}(\phi)$, 且 $\phi_j \geq 0$, $\sum_{j=1}^k \phi_j = 1$, $\phi_j = p(z^{(i)} = j)$ 。且 z 可以取 k 个值。 $x|z$ 服从正态分布, $x^{(i)} | (z^{(i)} = j) \sim \mathcal{N}(\mu_j, \Sigma_j)$ 。

换句话说, 我们的模型假设 x 的生成过程是, 先从 z 中取一个值出来表示这个 x 属于哪个高斯分布, 然后再从对应的高斯分布生成 x 。

2 参数估计

我们的模数包含三个参数, 首先是多项分布的参数 ϕ , 然后是正态分布的均值 μ 和方差 σ^2 。(只考虑 x 是一维, $x|z$ 符合一维正态分布的情况)

估计这三个参数, 我们采用最大化公式2所示的似然概率的方法。

$$\begin{aligned} \ell(\phi, \mu, \sigma) &= \sum_{i=1}^m \log p(x^{(i)}; \phi, \mu, \sigma) \\ &= \sum_{i=1}^m \log \sum_{z^{(i)}=1}^k p(x^{(i)} | z^{(i)}; \mu, \sigma) p(z^{(i)}; \phi) \end{aligned} \quad (2)$$

如果 z 的类别已知的话, 我们可以去掉公式2里面的求和符号, 因此我们只需要最大化3所示的似然概率即可。

$$\ell(\phi, \mu, \sigma) = \sum_{i=1}^m \log p(x^{(i)} | z^{(i)}; \mu, \sigma) + \log p(z^{(i)}; \phi) \quad (3)$$

我们要求似然函数的最大值点, 分别对 ϕ, μ, σ^2 进行求导。

求解 $\frac{\partial \ell}{\partial \phi_j}$: 约束条件 $\sum_{j=1}^k \phi_j = 1$ 。

使用拉格朗日乘数法求解条件极值, 令

$$\begin{aligned} F(\phi, \lambda) &= \ell(\phi, \mu, \sigma) + \lambda \left(\sum_{j=1}^k \phi_j - 1 \right) \\ s_j &= \sum_{i=1}^m 1 \{ z^{(i)} = j \} \end{aligned}$$

分别对 ϕ_j 以及 λ 进行求导, 可得:

$$\begin{cases} \frac{\partial F}{\partial \phi_j} = \frac{s_j}{\phi_j} + \lambda \\ \frac{\partial F}{\partial \lambda} = \sum_{j=1}^k \phi_j - 1 \end{cases}$$

令导数等于零，联立方程组求解，可得

$$\begin{aligned} \lambda &= -\sum_{j=1}^k s_j \\ \phi_j &= \frac{1}{m} \sum_{i=1}^m 1\{z^{(i)} = j\} \end{aligned} \quad (4)$$

求解 $\frac{\partial \ell}{\partial \mu_j}$: 似然函数只有前一项与 μ 有关，只考虑前一项即可。

将正态分布的公式 $f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$ 带入似然函数可得：

$$\ell(\phi, \mu, \sigma) \approx \sum_{i=1}^m \log\left(\frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x_i-\mu}{\sigma}\right)^2}\right) = -\sum_{i=1}^m \left[\log\sigma + \frac{1}{2}\log 2\pi + \frac{(x_i - \mu)^2}{2\sigma^2}\right]$$

求导令其导数为零：

$$\frac{\partial \ell}{\partial \mu_j} = \sum_{i=1}^m 1(z^{(i)} = j) \cdot 2(x_i - \mu_j) = 0$$

可得：

$$\mu_j = \frac{\sum_{i=1}^m 1\{z^{(i)} = j\} x^{(i)}}{\sum_{i=1}^m 1\{z^{(i)} = j\}} \quad (5)$$

求解 $\frac{\partial \ell}{\partial \sigma_j^2}$: 同样只用考虑似然函数的前一项。

$$\ell(\phi, \mu, \sigma) \approx -\sum_{i=1}^m \left[\log\sigma + \frac{1}{2}\log 2\pi + \frac{(x_i - \mu)^2}{2\sigma^2}\right]$$

求导令其导数为 0

$$\frac{\partial \ell}{\partial \sigma^2} = -\frac{1}{2} \sum_{i=1}^m 1(z^{(i)} = j) \left[\frac{1}{\sigma_j^2} - \frac{(x_i - \mu_j)^2}{\sigma_j^4}\right] = 0$$

可得

$$\sigma_j^2 = \frac{\sum_{i=1}^m 1(z^{(i)} = j)(x_i - \mu_j)^2}{\sum_{i=1}^m 1(z^{(i)} = j)} \quad (6)$$

3 EM 算法

在上一小节，我们固定 z ，求解出了模型参数的最优解。在 EM 算法中，我们采用迭代的方法进行优化。

在 EM 算法的 **Expectation** 阶段，我们首先使用贝叶斯公式求解出当前参数下， x 属于某个高斯分布的概率。

$$p(z^{(i)} = j | x^{(i)}; \phi, \mu, \Sigma) = \frac{p(x^{(i)} | z^{(i)} = j; \mu, \Sigma) p(z^{(i)} = j; \phi)}{\sum_{l=1}^k p(x^{(i)} | z^{(i)} = l; \mu, \Sigma) p(z^{(i)} = l; \phi)} \quad (7)$$

令

$$w_j^{(i)} := p(z^{(i)} = j \mid x^{(i)}; \phi, \mu, \Sigma)$$

在 **Maximization** 阶段，我们期望代替之前的 indicator 函数，并使用上一节推导出来的公式更新最优参数值。

$$\begin{aligned}\phi_j &:= \frac{1}{m} \sum_{i=1}^m w_j^{(i)} \\ \mu_j &:= \frac{\sum_{i=1}^m w_j^{(i)} x^{(i)}}{\sum_{i=1}^m w_j^{(i)}} \\ \sigma_j^2 &:= \frac{\sum_{i=1}^m w_j^{(i)} (x_i - \mu_j)^2}{\sum_{i=1}^m w_j^{(i)}}\end{aligned}\tag{8}$$

如此迭代进行，直至收敛。