

# Estimation of the Parameters of GMM with EM Algorithm by Minimizing Free Energy

赖泽强

2021 年 1 月 13 日

## 1 Introduction

回顾，在生成式模型中，我们希望求出数据的一个 parameterized distribution 最大化下面的似然概率：

$$P(X) = \prod_i^m P(x_i|\theta)$$

其中  $\theta$  为分布的参数，总共有  $m$  个样本点。对上式取  $\log$ ，改写成我们的目标函数：

$$L(\theta) = \sum_i^m \log P(x_i|\theta)$$

## 2 Gaussian Mixture Model

高斯混合模型假设我们的训练数据服从一系列高斯分布，每个样本点  $x$  出现的概率与其属于哪个高斯分布  $z$  有关。具体来说，我们假设数据服从下面的联合概率分布：

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

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  $x$ 。

## 3 Free Energies

基于高斯混合模型的假设，我们有：

$$\begin{aligned} L(\theta) &= \sum_i^m \log P(x_i|\theta) \\ &= \sum_i^m \log \int P(x_i, z|\theta) dz && \text{全概率公式} \\ &= \sum_i^m \log \int Q(z) \frac{P(x_i, z|\theta)}{Q(z)} dz \\ &\geq \sum_i^m \int Q(z) \log \frac{P(x_i, z|\theta)}{Q(z)} dz && \text{Jensen 不等式} \end{aligned} \quad (2)$$

由上式可知  $\sum_i^m \int Q(z) \log \frac{P(x_i, z|\theta)}{Q(z)} dz$  为  $L(\theta)$  的一个下界，我们可以通过最大化这个下界 ELBO 来得到  $L(\theta)$  的一个局部最优解。

令

$$\begin{aligned} F(Q, P) &= - \sum_i^m \int Q(z) \log \frac{P(x_i, z|\theta)}{Q(z)} dz \\ &= \sum_i^m \int Q(z) \log \frac{Q(z)}{P(x_i, z|\theta)} dz \end{aligned} \quad (3)$$

我们将  $F(Q, P)$  称为 **free energies**，且最大化 ELBO 等价于最小化 free energies。

## 4 EM Algorithm

### 4.1 E Step

由  $P(z|x) = \frac{P(x, z)}{P(x)}$ ，可得

$$\begin{aligned} F(Q, P) &= \sum_i^m \int Q(z) \log \frac{Q(z)}{P(x_i, z)} dz \\ &= \sum_i^m \int Q(z) \log \frac{Q(z)}{P(z|x_i)P(x)} dz \\ &= \sum_i^m [D[Q(z)||P(z|x_i)] - \log P(x_i)] \end{aligned}$$

在 E Step 中，我们固定  $\theta$ ，优化  $Q(z)$ 。因为  $\log P(x_i) = \log \int P(x|z)P(z)dz$  只与  $\theta$  有关，且 KL 散度  $D[Q(z)||P(z|x)] \geq 0$ ，仅当  $Q(z) \equiv P(z|x)$  时取等，所以在 E Step 中，我们有：

$$E \text{ Step: } Q_{k+1} = \underset{p}{\operatorname{argmin}} F[Q, P(\theta)] = P(z|x, \theta_k)$$

即当我们取  $Q(z) \equiv P(z|x)$  时， $F(Q, P)$  取到最小值。

### 4.2 M Step

在 M Step 中，我们将 E Step 估计出的  $Q(z) \equiv P(z|x)$  回代到  $F(Q, P)$  中：

$$\begin{aligned} F[Q_{k+1}, P(\theta)] &= \sum_i^m \int Q(z) \log \frac{Q(z)}{P(x_i, z)} dz \\ &= \sum_i^m \int P(z|x_i, \theta_k) \log \frac{P(z|x_i, \theta_k)}{P(x_i, z|\theta)} dz \\ &= \sum_i^m \left[ \int P(z|x_i, \theta_k) \log P(z|x_i, \theta_k) dz - \int P(z|x_i, \theta_k) \log P(x_i, z|\theta) dz \right] \end{aligned}$$

前一项使用的是上一步的  $\theta$ ，因此是个定值，所以我们有：

$$M \text{ Step: } \theta_{k+1} = \underset{\theta}{\operatorname{argmin}} F[Q_{k+1}, P(\theta)] = \underset{\theta}{\operatorname{argmin}} - \sum_i^m \int P(z|x_i, \theta_k) \log P(x_i, z|\theta) dz \quad (4)$$

## 5 EM For GMM

现在我们将上一节推导的 EM 更新公式代入 GMM 的具体表达式，推导 GMM 的参数更新方法。

$$M \text{ Step: } \theta_{k+1} = \underset{\theta}{\operatorname{argmin}} - \sum_i^m \int P(z|x_i, \theta_k) \log P(x_i, z|\theta) dz$$

$$E \text{ Step: } Q_{k+1} = P(z|x, \theta_k)$$

在 GMM 中，我们假设

$$P(z) \equiv \text{Multinomial}(\phi), \sum_{j=1}^c \phi_j = 1$$

$$P(x|z = j) \equiv \mathcal{N}(\mu_j, \Sigma_j)$$

### 5.1 E Step

E Step 直接使用贝叶斯公式即可

$$Q(z = i) = P(z = i|x, \theta_k) = \frac{P(x|z = i)P(z = i)}{\sum_j^c P(x|z = j)P(z = j)}$$

### 5.2 M Step

M Step 需要最大化:

$$\begin{aligned} \sum_i^m \int P(z|x_i, \theta_k) \log P(x_i, z|\theta) dz &= \sum_i^m \int P(z|x_i, \theta_k) \log [P(x_i|z, \mu, \Sigma) P(z|\phi)] dz \\ &= \sum_i^m (E[\log P(x_i|z, \mu, \Sigma)] + E[\log P(z|\phi)]) \end{aligned} \quad (5)$$

优化  $\phi$  :

$\phi$  只与后一项  $E[\log P(z|\phi)]$  有关,

$$\begin{aligned} E[\log P(z|\phi)] &= \sum_j^c P(z = j|x_i) \log P(z = j) \\ &= \sum_j^c P(z = j|x_i) \log \phi_j \end{aligned}$$

使用拉格朗日法引入约束条件,

$$L = F(Q, P) + \lambda \left( \sum_{j=1}^c \phi_j - 1 \right)$$

求导，令导数等于零:

$$\begin{aligned} \frac{\partial L}{\partial \phi_j} &= - \sum_i^m \frac{P(z = j|x_i)}{\phi_j} + \lambda = 0 \\ \frac{\partial L}{\partial \lambda} &= \sum_{j=1}^c \phi_j - 1 = 0 \end{aligned}$$

令

$$w_j^{(i)} = P(z = j|x_i)$$

$$s_j = \sum_i^m P(z = j|x_i) = \sum_i^m w_j^{(i)}$$

解方程组5.2, 可得

$$\lambda = \sum_{j=1}^c s_j \phi_j = \frac{s_j}{\sum_{j=1}^c s_j}$$

因为

$$\sum_{j=1}^c s_j = \sum_{j=1}^c \sum_{i=1}^m P(z = j|x_i) = \sum_{i=1}^m \sum_{j=1}^c P(z = j|x_i) = \sum_{i=1}^m 1 = m$$

所以

$$\phi_j = \frac{1}{m} \sum_{i=1}^m w_j^{(i)} \quad (6)$$

**优化  $\mu$**  :  $\mu$  只与公式5中的  $E[\log P(x_i|z, \mu, \Sigma)]$  有关:

$$\begin{aligned} E[\log P(x_i|z, \mu, \Sigma)] &= \sum_j^c P(z = j|x_i) \log P(x_i|z = j, \mu, \Sigma) \\ &= \sum_j^c w_j^{(i)} \log P(x_i|z = j, \mu, \Sigma) \\ &= \sum_j^c w_j^{(i)} \left[ \log \sigma_j + \frac{1}{2} \log 2\pi + \frac{(x_i - \mu_j)^2}{2\sigma_j^2} \right] \end{aligned}$$

求导, 令导数等于零:

$$\frac{\partial L}{\partial \mu_j} = \sum_{i=1}^m w_j^{(i)} \frac{(x_i - \mu_j)}{\sigma_j^2} = 0$$

解得

$$\mu_j = \frac{\sum_{i=1}^m w_j^{(i)} x_i}{\sum_{i=1}^m w_j^{(i)}} \quad (7)$$

**优化  $\Sigma = \sigma_1, \sigma_2, \dots, \sigma_c$**  :

同样只用考虑公式5的  $E[\log P(x_i|z, \mu, \Sigma)]$ :

$$\begin{aligned} E[\log P(x_i|z, \mu, \Sigma)] &= \sum_j^c w_j^{(i)} \left[ \log \sigma_j + \frac{1}{2} \log 2\pi + \frac{(x_i - \mu_j)^2}{2\sigma_j^2} \right] \\ &= \sum_j^c w_j^{(i)} \left[ \log \sqrt{\sigma_j^2} + \frac{1}{2} \log 2\pi + \frac{(x_i - \mu_j)^2}{2\sigma_j^2} \right] \end{aligned}$$

求导, 令导数等于零:

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

解得

$$\sigma_j^2 = \frac{\sum_{i=1}^m w_j^{(i)} (x_i - \mu_j)^2}{\sum_{i=1}^m w_j^{(i)}} \quad (8)$$

### 5.3 Summary

最终的 GMM 的 EM 更新公式如下：

$$\begin{aligned} \phi_j &= \frac{1}{m} \sum_{i=1}^m w_j^{(i)} \\ \mu_j &= \frac{\sum_{i=1}^m w_j^{(i)} x_i}{\sum_{i=1}^m w_j^{(i)}} \\ \sigma_j^2 &= \frac{\sum_{i=1}^m w_j^{(i)} (x_i - \mu_j)^2}{\sum_{i=1}^m w_j^{(i)}} \end{aligned} \quad (9)$$