

EM算法

VCG

数学工具和记号

期望

➤ 连续型随机变量 x ，概率密度 $p(x)$ 。函数 $f(x)$ 的期望

➤ $\mathbb{E}_{p(x)}[f(x)] = \int f(x)p(x)dx$

➤ 清晰地表明它是关于 $p(x)$ 的期望值

➤ 关于概率分布 $q(x)$ 的期望值

$$\mathbb{E}_{q(x)}[f(x)] = \int f(x)q(x)dx$$

➤ 参数 θ 的概率分布 $p(x; \theta)$ ，也可以写成 $p_\theta(x)$



KL 散度

➤ KL散度 $D_{\text{KL}}(p \parallel q)$: 用于衡量概率分布 $p(x)$ 和 $q(x)$ 之间差异

➤ x 为连续型随机变量

$$D_{\text{KL}}(p \parallel q) = \int p(x) \log \frac{p(x)}{q(x)} dx$$

➤ $\int p(x) \log \frac{p(x)}{q(x)} dx = \int p(x)(\log(-q(x)) - \log(-p(x)))dx$ 【相当于: 平均信息差】

➤ x 为离散型随机变量

$$D_{\text{KL}}(p \parallel q) = \sum_x p(x) \log \frac{p(x)}{q(x)}$$

➤ KL 散度特性

➤ 两个概率分布的差异越大，KL 散度的值就越大。

➤ KL 散度的值大于或等于 0，且仅当两个概率分布相同时，其值才为 0

➤ KL 散度非对称， $D_{\text{KL}}(p \parallel q)$ 和 $D_{\text{KL}}(q \parallel p)$ 的值不同

最大似然估计 (Maximum Likelihood Estimation)

最大似然估计

- 概率分布 p , 由参数 θ 决定: $p(x; \theta)$; 例如, 正态分布参数 $\theta = \{\mu, \sigma\}$
- 样本 $\mathcal{D} = \{x^{(1)}, x^{(2)}, \dots, x^{(N)}\}$, 数据基于概率分布 $p(x; \theta)$ 独立生成
 - 当参数为 θ 时, 获得样本 \mathcal{D} 的概率密度

$$L(\theta) = p(\mathcal{D}; \theta) = p(x^{(1)}; \theta)p(x^{(2)}; \theta) \cdots p(x^{(N)}; \theta) = \prod_{n=1}^N p(x^{(n)}; \theta)$$

- $L(\theta)$ 称为似然 (likelihood) 或似然函数 (likelihood function)
- 以参数 θ 为参数的函数, 表示在给定参数 θ 的情况下, 样本 \mathcal{D} 出现的概率密度

- 最大似然估计: 找到使似然 $p(\mathcal{D}; \theta)$ 最大的参数 θ

$$\hat{\theta} = \operatorname{argmax}_{\theta} \prod_{n=1}^N p(x^{(n)}; \theta)$$

- $\hat{\theta}$ 为观测到样本的概率最大, 模型最拟合样本
- 常用对数似然 $\log p(\mathcal{D}; \theta)$ 的最大化 $\hat{\theta} = \operatorname{argmax}_{\theta} \sum_{n=1}^N \log p_{\theta}(x^{(n)})$

似然函数优化与ELBO

优化目标：似然函数

➤ 似然函数的基础项

$$\log p_\theta = \log \sum_z p_\theta(x, z)$$

➤ 偏导

$$\frac{\partial \log p_\theta}{\partial \theta} = \frac{1}{\sum_z p_\theta(x, z)} \sum_z \frac{\partial}{\partial \theta} p_\theta(x, z)$$

➤ log-sum形式，优化存在问题

➤ 各个参数项紧密耦合， $\frac{1}{\sum_z p_\theta(x, z)}$ 为包含了所有的 $p_\theta(x, z)$ 项共同的分母项

➤ 意味着参数 θ 对 $p_\theta(x, z)$ 的微小改变，其对总体梯度的贡献，会受到其他项 $p_\theta(x, z)$ 的影响

优化形式：sum-log与log-sum

sum-log与log-sum

➤ 优化通常通过参数 (θ) 偏导并令其为零来实现，两种形式

➤ $L(\theta) = \sum_i \log f_i(\theta)$ 【sum-log】

$$\triangleright \frac{\partial L}{\partial \theta} = \sum_i \frac{\partial}{\partial \theta} \log f_i(\theta) = \sum_i \frac{1}{f_i(\theta)} \frac{\partial f_i(\theta)}{\partial \theta}$$

➤ 每个 $f_i(\theta)$ 的导数独立计算，然后简单相加。可以分别处理每一项

➤ $L(\theta) = \log(\sum_i f_i(\theta))$ 【log-sum】

$$\triangleright \frac{\partial L}{\partial \theta} = \frac{1}{\sum_j f_j(\theta)} \cdot \left(\sum_i \frac{\partial f_i(\theta)}{\partial \theta} \right)$$

➤ 包含了所有的 $f_i(\theta)$ 项共同的分母项

➤ 意味着参数 θ 对 $f_i(\theta)$ 的微小改变，其对总体梯度的贡献，会受到其他项 $f_j(\theta)$ 的影响

sum-of-log与log-of-sum

➤ 实际上，似然函数中还有其它项，即

$$\triangleright \frac{\partial L}{\partial \theta} = \sum_i \frac{1}{f_i(\theta)} \frac{\partial f_i(\theta)}{\partial \theta} + (\text{其它项}) \quad [\text{sum-log}]$$

$$\triangleright \frac{\partial L}{\partial \theta} = \frac{1}{\sum_j f_j(\theta)} \cdot \left(\sum_i \frac{\partial f_i(\theta)}{\partial \theta} \right) + (\text{其它项}) \quad [\text{log-sum}]$$

➤ log-of-sum的问题


➤ 优化时，令 $\frac{\partial L}{\partial \theta} = 0$ ，对于 log-of-sum 结构，得到一个复杂方程，其中所有参数都通过分母紧密地耦合在一起

➤ 通常，这个log-sum方程没有解析解 (closed-form solution)

似然函数的推导

EM算法的变分推断视角

- 【优化目标】对数似然函数 $\log p_\theta$ 。其中， θ 是要学习的模型参数
- 【思想】引入隐变量 z 及其变分分布 $q(z)$ ，将对 θ 的优化转为对 (θ, q) 的联合优化
- 【策略】最大化对数似然转为最大化它的下界(ELBO)。通过交替优化ELBO，单调提升 $\log p_\theta$ 的值，对应着EM算法的E步和M步
 - E步(变分步 / Expectation Step)
 - 固定当前模型参数 θ ，将 $q(z)$ 调整到最优。即令 $q(z) = p(z|x, \theta)$
 - 此时，ELBO被提升至紧贴真实的对数似然函数值，得到当前参数 θ 的最优下界
 - 等价于构建了完整数据的对数似然期望（Q函数）
 - 【当前模型参数下的，隐变量后验分布 $p(z|x, \theta)$ 的最优估计；故称变分步】
 - M步 (最大化步 / Maximization Step)
 - 固定上一步得到的最优分布 $q(z)$ ，调整模型参数 θ ，最大化当前的ELBO
 - 得到新的模型参数
 - 由于下界被抬高，真实对数似然也随之被保证单调提升
 - 【当前隐函数分布下的，对模型参数的最优估计】



变分分布 $q(z)$ 的分析

【优化项】 $\log p_\theta(x) = \log \frac{p_\theta(x, z)}{q(z)} + \log \frac{q(z)}{p_\theta(z|x)}$


【分析】用辅助变分分布 $q(z)$ 对后验分布 $p_\theta(z|x)$ ($p_\theta(z|x)$ 给定观测数据 x , 猜测其潜在变量 z 分布) 进行最优估计。因此, 需要拼凑出 $\frac{q(z)}{p_\theta(z|x)}$ 项!

$$\log p_\theta(x) = \log \frac{p_\theta(x, z)}{p_\theta(z|x)} \quad \text{【引入数据到隐变量的条件后验概率 } p_\theta(z|x) \text{】}$$

$$= \log \frac{p_\theta(x, z)}{p_\theta(z|x)} \frac{q(z)}{q(z)} \left(\text{乘以 } \frac{q(z)}{q(z)} = 1 \right) \quad \text{【引入任意的隐变量分布 } q(z) \text{】}$$

$$= \log \frac{p_\theta(x, z)}{q(z)} + \log \frac{q(z)}{p_\theta(z|x)} \quad \text{【引入隐变量分布和后验分布的差异】}$$

于是, $\log p_\theta(x) = \log \frac{p_\theta(x, z)}{q(z)} + \log \frac{q(z)}{p_\theta(z|x)}$



ELBO

【优化项】 $\log p_\theta(x) = \log \frac{p_\theta(x,z)}{q(z)} + \log \frac{q(z)}{p_\theta(z|x)}$

$\sum_z q(z) = 1$, 则 $\mathbb{E}_{z \sim q(z)} 1 = 1$, 而 $\log p_\theta(x) = \log \frac{p_\theta(x,z)}{q(z)} + \log \frac{q(z)}{p_\theta(z|x)}$ 与 z 无关, 于是

$\log p(x) = \mathbb{E}_{z \sim q(z)} [\log p(x)]$ 【期望项与 z 无关, 当常数看】

$$= \mathbb{E}_{z \sim q(z)} \left[\log \frac{p_\theta(x,z)}{q(z)} + \log \frac{q(z)}{p_\theta(z|x)} \right]$$
 【拆分期望项】

$$= \mathbb{E}_{z \sim q(z)} \left[\log \frac{p_\theta(x,z)}{q(z)} \right] + \mathbb{E}_{z \sim q(z)} \left[\log \frac{q(z)}{p_\theta(z|x)} \right]$$
 【期望的线性性质】



$$= \text{ELBO}(x; q, \theta) + D_{\text{KL}}(q(z) \parallel p_\theta(z|x))$$

其中, $\text{ELBO}(x; q, \theta) \stackrel{\text{def}}{=} \mathbb{E}_{z \sim q(z)} \left[\log \frac{p_\theta(x,z)}{q(z)} \right]$ 【sum-log形式, 可以解析!!】

似然函数优化 – E步



- 【优化项】 $\log p(x) = \text{ELBO}(x; q, \theta) + D_{\text{KL}}(q(z) \parallel p_{\theta}(z | x))$
- E步：固定模型参数 $\theta = \theta_{\text{old}}$, 优化 $q(z)$
 - $\log p(x)$ 与 z 无关，不能更大。因此，优化目标转为原目标函数的下界ELBO，让 D_{KL} 最小即可
 - 于是， $D_{\text{KL}} = 0$; 从而， $q(z) = p_{\theta_{\text{old}}}(z | x)$
 - 用后验概率 $p_{\theta}(z | x)$ 作为对隐变量分布的最佳猜测 $q(z)$
 - 即，现有模型给出了缺失信息的一个最合理猜测
- ELBO更新

$$\text{ELBO}(x; q = p_{\theta_{\text{old}}}, \theta) = \mathbb{E}_{p_{\theta_{\text{old}}}(z|x)} \left[\log \frac{p_{\theta}(x,z)}{p_{\theta_{\text{old}}}(z|x)} \right]$$



似然函数优化 – M步

- 【优化项】 $\log p(x) = \text{ELBO}(x; q, \theta) + D_{\text{KL}}(q(z) \parallel p_{\theta}(z \mid x))$
- M步：固定隐变量分布 $q(z) = q_{\text{old}}(z)$, 优化 θ
 - D_{KL} 与 θ 无关，因此，最大化 $\text{ELBO}(x; q, \theta)$ 即可
 - 通过ELBO更新参数 θ
 - 实际上此步骤为标准的最大似然，于是，新模型更适应当前的隐变量分布 $q_{\text{old}}(z)$
- 新一轮E步和M步



单调有界

- ELBO单调上升，且有上界，故EM算法收敛