

Gibbs Sampling Derivation for LDA and TOT

Hewlett-Packard Laboratories, China

Han Xiao, Ping Luo

January 19, 2009

A. Notations

整个 corpus 中包含 D 个 document，有 T 个 topics，且 vocabulary 的大小为 V ；

粗体的 $\mathbf{w}, \mathbf{z}, \mathbf{t}$ 分别泛指整个 corpus 中的 word, topic 和 timestamp；

小写的 d 代表 document 的索引，表示某一篇 document, $d=1$ to D

N_d 表示第 d 个 document 中 word 的数量

小写的 i 表示 word 的索引, $i=1$ to N_d , 与 d 合用可以组成 $w_{di}, z_{di}, d_{di}, t_{di}$ ：

- w_{di} 表示第 d 个 document 中第 i 个 word,
- z_{di} 表示第 d 个 document 中第 i 个 word 生成自哪个 topic,
- d_{di} 表示第 d 个 document 中第 i 个 word 来自哪个 document,
- t_{di} 表示第 d 个 document 中第 i 个 word 的 time stamp

注意对于不同的 i, j , w_{di}, w_{dj} 可以指示相同的 word, 也可以指示不同的 word, 对于 z_{di}, t_{di}, d_{di} 也同理。对于整个 corpus, 一共有 $D \cdot N_d$ 个 word, 也就对应 $D \cdot N_d$ 个 topic 和 $D \cdot N_d$ 个 timestamp。但整个 corpus 中实际只有 V 个无重复的 word, T 个无重复的 topic, 因此我们用：

- 小写的 z 表示无重复的 topic 索引, $z=1$ to T
- 小写的 v 表示无重复的 word 索引, $v=1$ to V

在后面的推导过程中, 会用到

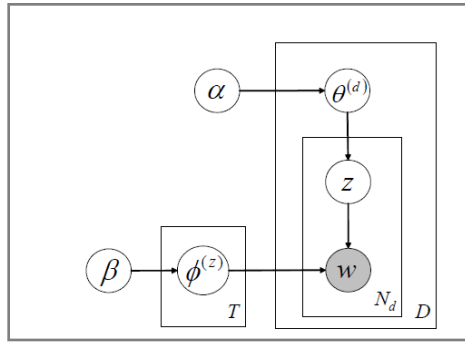
- $n_{z,v}$ 表示第 z 个 topic 和第 v 个 word 的共现次数 (即 word v 多少次是由 topic z 生成的)。
- $n_{d,z}$ 表示第 d 个 document 和第 z 个 topic 的共现次数 (即 topic z 在 document d 中出现了多少次)

在 LDA 中, 每个 document 都有一个在所有 topics 上的分布, 每个 topic 都有一个在整个 vocabulary 上的分布。对于 TOT 每个 topic 还有一个 beta 分布来表示时间。这里用大写的 Ψ 表示 beta 分布集, Φ, Θ 表示多项分布集, 其中每一个分布用如下小写符号表示：

- $\phi_{z_{di}}$ 表示 z_{di} 所对应的 topic-words 多项式分布
- ϕ_z 表示第 z 个 topic 对应的 topic-words 多项式分布
- β 为控制 topic-words 多项式分布的 dirichlet 先验分布参数, 由 dirichlet(β) 抽出的都是 topic-words 多项式分布, 即 ϕ_z 。在后面的推导中, 为了不失一般化, 使用的是非对称的 dirichlet 分布, 参数用 β_v 表示, 一共有 V 个 β 。
- θ_d 表示第 d 个 document 的 document-topics 多项分布
- α 为控制 document-topics 多项式分布的 dirichlet 先验分布参数, 由 dirichlet(α) 抽出的都是 document-topics 多项式分布, 即 θ_d 。同样的, 对于非对称的 dirichlet 分布, 参数用 α_z 表示, 一共有 T 个 α
- $\psi_{z_{di}}$ 表示 z_{di} 所对应的 beta 分布
- $\psi_{z_{di}}^1$ 和 $\psi_{z_{di}}^2$ 表示 z_{di} 所对应的 beta 分布的两个参数

B. Generating Process

LDA(Latent Dirichlet Allocation, D.Blei etc., 2003)的 Graphical Model 如下：




其生成过程为:

0. 设定 T , $\alpha_1, \dots, \alpha_T$, β_1, \dots, β_V
1. 对于每一个 topic, 从参数为 β 的 Dirichlet 先验分布中抽样, 并作为 1 个多项分布 ϕ_z ; 重复 T 次
2. 对于每一个 document, 从参数为 α 的 Dirichlet 先验分布中抽样, 并作为 1 个多项分布 θ_d , 为了生成这个 document 中的每一个 word w_{di} :
 - a) 从多项分布 θ_d 中抽取一个 topic z_{di}
 - b) 从多项分布 $\phi_{z_{di}}$ 中抽取一个 word w_{di}
 - c) 重复(a,b) N_d 次
3. 重复步骤 2 D 次, 直到整个 corpus 生成完成。

LDA 的目标: 根据已有的 corpus(每个 word 是观察到的)重建 θ_d 和 $\phi_{z_{di}}$, 难点: 每个 word w_{di} 对应的 topic z_{di} 是未知的 (z 是隐藏变量)

TOT(Topics over Time: A Non-Markov Continuous-Time Model of Topical Trends, Xuerui Wang etc., 2006)的 Graphical Model 如下:



其目的在于描述一个 corpus 中随时间变化 topic。其生成过程为:

0. 设定 T , $\alpha_1, \dots, \alpha_T$, β_1, \dots, β_V
1. 对于每一个 topic, 从参数为 β 的 Dirichlet 先验分布中抽样, 并作为 1 个多项分布 ϕ_z ; 重复 T 次
2. 对于每一个 document, 从参数为 α 的 Dirichlet 先验分布中抽样, 并作为 1 个多项分布 θ_d , 为了生成这个 document 中的每一个 word w_{di} :
 - a) 从多项分布 θ_d 中抽取一个 topic z_{di}
 - b) 从多项分布 $\phi_{z_{di}}$ 中抽取一个 word w_{di}
 - c) 从 beta 分布 $\psi_{z_{di}}$ 中抽取一个 timestamp t_{di}
 - d) 重复(a,b,c) N_d 次
3. 重复步骤 2 D 次, 直到整个 corpus 生成完成。

TOT 的目标: 根据已有的 corpus(每个 word 是观察到的, 每个 word 上的 timestamp 用其所在的 document 的生成时间表示)重建 θ_d , $\phi_{z_{di}}$ 和 $\psi_{z_{di}}$, 难点: 每个 word w_{di} 对应的 topic z_{di} 是未知的 (z 是隐藏变量)

C. Derivation of Gibbs Sampling

Gibbs Sampling: 为了对 \mathbf{X} 进行估计, 一般我们要从

$$P(\mathbf{X}) \equiv P(x_1, x_2, \dots, x_N)$$

中进行抽样。如果 $P(\mathbf{X})$ 不易求得, 我们可以通过对所有的 $P(x_i | \mathbf{X}_{-i})$ 进行抽样来近似 $\hat{\mathbf{X}}$ 其步骤如下:

1. 随机初始化 $\mathbf{X}^{(0)} = \{x_1^{(0)}, x_2^{(0)}, \dots, x_N^{(0)}\}$
2. 重复进行 T 轮抽样, $t=1, \dots, T$

在每轮抽样中, 对于 $i=1, \dots, N$, 每个 $x_i^{(t)}$ 从 $P(x_i^{(t)} | \mathbf{X}_1^{(t)}, \dots, \mathbf{X}_{i-1}^{(t)}, \mathbf{X}_{i+1}^{(t-1)}, \dots, \mathbf{X}_N^{(t)})$ 抽样

3. 当 Burn-in 之后, 可以通过几轮抽样计算 $P(\mathbf{X})$

为了不失一般性, 下面对 TOT 的 Gibbs Sampling 过程进行推导

1. 在 TOT 的 Gibbs Sampling 中, 我们要求

$$P(z_{di} | \mathbf{w}, \mathbf{t}, \mathbf{z}_{-di}, \alpha, \beta, \Psi)$$

然后才能跟据它, 对生成 w_{di}, t_{di} 的 z_{di} 进行抽样估计。因为 z_{di} 是隐藏变量, 一旦抽样估计完成, 对于每个 w_{di} 它生成自的 topic 就变成已知; 对于每个 document, 它包含的 topics 也变成已知。那么对于 document-topics 分布 θ_d 和 topic-words 上的分布 ϕ_z 也就可以非常容易的被拟合出来。

Step 1: 根据

$$P(z_{di}, \mathbf{z}_{-di}) = P(\mathbf{z})$$

和贝叶斯公式可以得到

$$P(z_{di} | \mathbf{w}, \mathbf{t}, \mathbf{z}_{-di}, \alpha, \beta, \Psi) = \frac{P(\mathbf{w}, \mathbf{t}, \mathbf{z}, \alpha, \beta, \Psi)}{P(\mathbf{w}, \mathbf{t}, \mathbf{z}_{-di}, \alpha, \beta, \Psi)} = \frac{P(\mathbf{w}, \mathbf{t}, \mathbf{z} | \alpha, \beta, \Psi)}{P(\mathbf{w}, \mathbf{t}, \mathbf{z}_{-di} | \alpha, \beta, \Psi)}$$

根据 Graphical Model, w_{di}, t_{di} 都是由 z_{di} 生成的, 如果不考虑 z_{di} 则无法考虑 w_{di}, t_{di} 。从而得到:

$$P(z_{di} | \mathbf{w}, \mathbf{t}, \mathbf{z}_{-di}, \alpha, \beta, \Psi) \propto \frac{P(\mathbf{z}, \mathbf{w}, \mathbf{t} | \alpha, \beta, \Psi)}{P(\mathbf{z}_{-di}, \mathbf{w}_{-di}, \mathbf{t}_{-di} | \alpha, \beta, \Psi)}$$

2. 由上式可知, 在 Gibbs Sampling 中关键是要求出如下的联合概率

$$P(\mathbf{w}, \mathbf{t}, \mathbf{z} | \alpha, \beta, \Psi)$$

Step 1: 根据 Graphical Model, 略去 Φ, Θ , 可以将联合概率拆开

$$P(\mathbf{w}, \mathbf{t}, \mathbf{z} | \alpha, \beta, \Psi) = P(\mathbf{w} | \mathbf{z}, \beta) P(\mathbf{t} | \Psi, \mathbf{z}) P(\mathbf{z} | \alpha)$$

Step 2: 引入 Φ, Θ , 对 Φ, Θ 进行积分。再根据 Graphical Model, 可以写出

$$P(\mathbf{w}, \mathbf{t}, \mathbf{z} | \alpha, \beta, \Psi) = P(\mathbf{t} | \Psi, \mathbf{z}) \int P(\mathbf{w} | \mathbf{z}, \Phi) P(\Phi | \beta) d\Phi \int P(\mathbf{z} | \Theta) P(\Theta | \alpha) d\Theta$$

Step 3: 对于整个 corpus, 拆开所有黑体和大写, 条件概率中的条件 Ψ, \mathbf{z} 可以写做 $\psi_{z_{di}}$; \mathbf{z}, Φ 写做 $\phi_{z_{di}}$

$$= \prod_{d=1}^D \prod_{i=1}^{N_d} P(t_{di} | \psi_{z_{di}}) \int \prod_{d=1}^D \prod_{i=1}^{N_d} P(w_{di} | \phi_{z_{di}}) \prod_{z=1}^T P(\phi_z | \beta) d\phi_z \int \prod_{d=1}^D \prod_{i=1}^{N_d} P(z_{di} | \theta_d) P(\theta_d | \alpha) d\theta_d$$

Step 4: 由于从第 z_{di} 个 topic 中抽去 w_{di} 是满足多项式分布 $\phi_{z_{di}}$ 的, 因此

$$\prod_{d=1}^D \prod_{i=1}^{N_d} P(w_{di} | \phi_{z_{di}}) = \prod_{z=1}^T \prod_{v=1}^V \phi_{z,v}^{n_{z,v}}$$

同理由于从第 d 个 document 中抽取 z_{di} 也是满足多项分布 θ_d 的, 因此

$$\prod_{d=1}^D \prod_{i=1}^{N_d} P(z_{di} | \theta_d) = \prod_{d=1}^D \prod_{z=1}^T \theta_{d,z}^{n_{d,z}}$$

将两式带入(2.3)中可以得到,

$$= \prod_{d=1}^D \prod_{i=1}^{N_d} P(t_{di} | \psi_{z_{di}}) \int \prod_{z=1}^T \prod_{v=1}^V \phi_{z,v}^{n_{z,v}} \prod_{z=1}^T P(\phi_z | \beta) d\phi_z \int \prod_{d=1}^D \prod_{z=1}^T \theta_{d,z}^{n_{d,z}} \prod_{d=1}^D P(\theta_d | \alpha) d\theta_d$$

Step 5: 根据 dirichlet 的后验分布, 可以将 $P(\phi_z | \beta)$ 和 $P(\theta_d | \alpha)$ 展开, 得到

$$= \prod_{d=1}^D \prod_{i=1}^{N_d} P(t_{di} | \psi_{z_{di}}) \int \prod_{z=1}^T \prod_{v=1}^V \phi_{z,v}^{n_{z,v}} \prod_{z=1}^T \left(\frac{\Gamma(\sum_{v=1}^V \beta_v)}{\prod_{v=1}^V \Gamma(\beta_v)} \prod_{v=1}^V \phi_{z,v}^{\beta_v - 1} \right) d\phi_z \int \prod_{d=1}^D \prod_{z=1}^T \theta_{d,z}^{n_{d,z}} \prod_{d=1}^D \left(\frac{\Gamma(\sum_{z=1}^T \alpha_z)}{\prod_{z=1}^T \Gamma(\alpha_z)} \prod_{z=1}^T \theta_{d,z}^{\alpha_z - 1} \right) d\theta_d$$

Step 6: 由于 $\frac{\Gamma(\sum_{v=1}^V \beta_v)}{\prod_{v=1}^V \Gamma(\beta_v)}$ 与 ϕ 无关, $\frac{\Gamma(\sum_{z=1}^T \alpha_z)}{\prod_{z=1}^T \Gamma(\alpha_z)}$ 与 θ 无关, 可以将它们提出, 得:

$$= \prod_{d=1}^D \prod_{i=1}^{N_d} P(t_{di} | \psi_{z_{di}}) \left(\frac{\Gamma(\sum_{v=1}^V \beta_v)}{\prod_{v=1}^V \Gamma(\beta_v)} \right)^T \left(\frac{\Gamma(\sum_{z=1}^T \alpha_z)}{\prod_{z=1}^T \Gamma(\alpha_z)} \right)^D \int \prod_{z=1}^T \prod_{v=1}^V \phi_{z,v}^{n_{z,v}} \prod_{z=1}^T \left(\prod_{v=1}^V \phi_{z,v}^{\beta_v - 1} \right) d\phi_z \int \prod_{d=1}^D \prod_{z=1}^T \theta_{d,z}^{n_{d,z}} \prod_{d=1}^D \left(\prod_{z=1}^T \theta_{d,z}^{\alpha_z - 1} \right) d\theta_d$$

Step 7: 由于不同的 topic 的 topic-words 分布是独立的 (比如 ϕ_1 与 ϕ_2 是独立的, 可以通过 d-separation 判定), 因此连乘的积分可以写作积分的连乘; 同理, 不同 document 的 document-topics 分布也是独立的 (θ_1 与 θ_2 是独立的), 因此以上式可以写为:

$$= \prod_{d=1}^D \prod_{i=1}^{N_d} P(t_{di} | \psi_{z_{di}}) \left(\frac{\Gamma(\sum_{v=1}^V \beta_v)}{\prod_{v=1}^V \Gamma(\beta_v)} \right)^T \left(\frac{\Gamma(\sum_{z=1}^T \alpha_z)}{\prod_{z=1}^T \Gamma(\alpha_z)} \right)^D \prod_{z=1}^T \left(\int \prod_{v=1}^V \phi_{z,v}^{n_{z,v} + \beta_v - 1} d\phi_z \right) \prod_{d=1}^D \left(\int \prod_{z=1}^T \theta_{d,z}^{n_{d,z} + \alpha_z - 1} d\theta_d \right)$$

Step 8: 根据欧拉积分

$$\int \prod_{i=1}^N x_i^{a_i - 1} d^N \vec{x} = \frac{\prod_{i=1}^N \Gamma(a_i)}{\Gamma(\sum_{i=1}^N a_i)}$$

对(2.7)式中后面两项使用欧拉积分可得

$$P(\mathbf{w}, \mathbf{t}, \mathbf{z} | \alpha, \beta, \Psi) = \prod_{d=1}^D \prod_{i=1}^{N_d} P(t_{di} | \psi_{z_{di}}) \left(\frac{\Gamma(\sum_{v=1}^V \beta_v)}{\prod_{v=1}^V \Gamma(\beta_v)} \right)^T \left(\frac{\Gamma(\sum_{z=1}^T \alpha_z)}{\prod_{z=1}^T \Gamma(\alpha_z)} \right)^D \prod_{z=1}^T \frac{\prod_{v=1}^V \Gamma(n_{z,v} + \beta_v)}{\Gamma(\sum_{v=1}^V n_{z,v} + \beta_v)} \prod_{d=1}^D \frac{\prod_{z=1}^T \Gamma(n_{d,z} + \alpha_z)}{\Gamma(\sum_{z=1}^T (n_{d,z} + \alpha_z))}$$

3. 求 full conditional probability

Step 1: 将(2.8)中的式子代入, 可以得到

$$\frac{P(\mathbf{z}, \mathbf{w}, \mathbf{t} | \alpha, \beta, \Psi)}{P(\mathbf{z}_{-di}, \mathbf{w}_{-di}, \mathbf{t}_{-di} | \alpha, \beta, \Psi)} = \frac{\prod_{d=1}^D \prod_{i=1}^{N_d} P(t_{di} | \psi_{z_{di}}) \left(\frac{\Gamma(\sum_{v=1}^V \beta_v)}{\prod_{v=1}^V \Gamma(\beta_v)} \right)^T \left(\frac{\Gamma(\sum_{z=1}^T \alpha_z)}{\prod_{z=1}^T \Gamma(\alpha_z)} \right)^D \prod_{z=1}^T \frac{\prod_{v=1}^V \Gamma(n_{z,v} + \beta_v)}{\Gamma(\sum_{v=1}^V n_{z,v} + \beta_v)} \prod_{d=1}^D \frac{\prod_{z=1}^T \Gamma(n_{d,z} + \alpha_z)}{\Gamma(\sum_{z=1}^T (n_{d,z} + \alpha_z))}}{\left[\prod_{d=1}^D \prod_{i=1}^{N_d} P(t_{di} | \psi_{z_{di}}) \left(\frac{\Gamma(\sum_{v=1}^V \beta_v)}{\prod_{v=1}^V \Gamma(\beta_v)} \right)^T \left(\frac{\Gamma(\sum_{z=1}^T \alpha_z)}{\prod_{z=1}^T \Gamma(\alpha_z)} \right)^D \prod_{z=1}^T \frac{\prod_{v=1}^V \Gamma(n_{z,v} + \beta_v)}{\Gamma(\sum_{v=1}^V n_{z,v} + \beta_v)} \prod_{d=1}^D \frac{\prod_{z=1}^T \Gamma(n_{d,z} + \alpha_z)}{\Gamma(\sum_{z=1}^T (n_{d,z} + \alpha_z))} \right]_{-di}}$$

Step 2: 此时, 要留意所有角标与 di 有关的 $n_{d,z}$ 和 $n_{z,v}$, 由于不考虑 z_{di} , 因此 $w_{di} t_{di}$ 不用考虑 (因为它们没有被生成), 也就是说在考虑 topic z 和 word v 的所有共现次数时 (即 $n_{z,v}$), 我们忽略了这一次 z_{di} 与 w_{di} 的共现, 这仅仅会让 $n_{z_{di}, w_{di}}$ 减 1, 而对于其他的 $n_{z, w_{di}}$ 并无影响; 同样的, 这也会使 $n_{d_{di}, z_{di}}$ 减 1, 而并不会使其他的 $n_{d, z_{di}}$ 发生改变。注意: V, T, D 的大小并没有发生改变

将上式拆成 3 部分来看, 可以得到如下三式:

$$1) \frac{\prod_{d=1}^D \prod_{i=1}^{N_d} P(t_{di} | \psi_{z_{di}})}{\left[\prod_{d=1}^D \prod_{i=1}^{N_d} P(t_{di} | \psi_{z_{di}}) \right]_{-di}} = P(t_{di} | \psi_{z_{di}})$$

$$2) \frac{\left(\frac{\Gamma(\sum_{v=1}^V \beta_v)}{\prod_{v=1}^V \Gamma(\beta_v)} \right)^T \left(\frac{\Gamma(\sum_{z=1}^D \alpha_z)}{\prod_{z=1}^D \Gamma(\alpha_z)} \right)^D}{\left[\frac{\Gamma(\sum_{v=1}^V \beta_v)}{\prod_{v=1}^V \Gamma(\beta_v)} \right]^T \left[\frac{\Gamma(\sum_{z=1}^D \alpha_z)}{\prod_{z=1}^D \Gamma(\alpha_z)} \right]^D} = 1$$

$$3) \frac{\prod_{z=1}^T \frac{\prod_{v=1}^V \Gamma(n_{z,v} + \beta_v)}{\Gamma(\sum_{v=1}^V (n_{z,v} + \beta_v))} \prod_{d=1}^D \frac{\prod_{z=1}^T \Gamma(n_{d,z} + \alpha_z)}{\Gamma(\sum_{z=1}^T (n_{d,z} + \alpha_z))}}{\left[\prod_{z=1}^T \frac{\prod_{v=1}^V \Gamma(n_{z,v} + \beta_v)}{\Gamma(\sum_{v=1}^V (n_{z,v} + \beta_v))} \prod_{d=1}^D \frac{\prod_{z=1}^T \Gamma(n_{d,z} + \alpha_z)}{\Gamma(\sum_{z=1}^T (n_{d,z} + \alpha_z))} \right]}_{-di}$$

Step 3: 关键是对(3.2.3 式的化简), 首先看其前一部分的分母

$$\left[\prod_{z=1}^T \frac{\prod_{v=1}^V \Gamma(n_{z,v} + \beta_v)}{\Gamma(\sum_{v=1}^V (n_{z,v} + \beta_v))} \right]_{-di} = \frac{\Gamma(n_{z_{di}, w_{di}} + \beta_{w_{di}} - 1) \times \left[\prod_{z=1}^T \prod_{v=1}^V \Gamma(n_{z,v} + \beta_v) \right]_{-z_{di}, w_{di}}}{\Gamma(\sum_{v=1}^V (n_{z_{di}, v} + \beta_v) - 1) \times \prod_{z \neq z_{di}}^T \Gamma(\sum_{v=1}^V (n_{z,v} + \beta_v))}$$

Step 4: 看前一部分的分子

$$\prod_{z=1}^T \frac{\prod_{v=1}^V \Gamma(n_{z,v} + \beta_v)}{\Gamma(\sum_{v=1}^V (n_{z,v} + \beta_v))} = \frac{\Gamma(n_{z_{di}, w_{di}} + \beta_{w_{di}}) \times \left[\prod_{z=1}^T \prod_{v=1}^V \Gamma(n_{z,v} + \beta_v) \right]_{-z_{di}, w_{di}}}{\Gamma(\sum_{v=1}^V (n_{z_{di}, v} + \beta_v)) \times \prod_{z \neq z_{di}}^T \Gamma(\sum_{v=1}^V (n_{z,v} + \beta_v))}$$

Step 5: (3.4)/(3.3), 借助 $\Gamma(x+1) = x\Gamma(x)$ 可以得到

$$\frac{\prod_{z=1}^T \frac{\prod_{v=1}^V \Gamma(n_{z,v} + \beta_v)}{\Gamma(\sum_{v=1}^V (n_{z,v} + \beta_v))}}{\left[\prod_{z=1}^T \frac{\prod_{v=1}^V \Gamma(n_{z,v} + \beta_v)}{\Gamma(\sum_{v=1}^V (n_{z,v} + \beta_v))} \right]_{-di}} = \frac{n_{z_{di}, w_{di}} + \beta_{w_{di}} - 1}{\sum_{v=1}^V (n_{z_{di}, v} + \beta_v) - 1}$$

Step 6: 看后一部分的分母

$$\left[\prod_{d=1}^D \frac{\prod_{z=1}^T \Gamma(n_{d,z} + \alpha_z)}{\Gamma(\sum_{z=1}^T (n_{d,z} + \alpha_z))} \right]_{-di} = \frac{\Gamma(n_{d_{di}, z_{di}} + \alpha_{z_{di}} - 1) \times \left[\prod_{d=1}^D \prod_{z=1}^T \Gamma(n_{d,z} + \alpha_z) \right]_{-d_{di}, z_{di}}}{\Gamma(\sum_{z=1}^T (n_{d_{di}, z} + \alpha_z) - 1) \times \prod_{d \neq d_{di}}^D \Gamma(\sum_{z=1}^T (n_{d,z} + \alpha_z))}$$

Step 7: 看后一部分的分子:

$$\prod_{d=1}^D \frac{\prod_{z=1}^T \Gamma(n_{d,z} + \alpha_z)}{\Gamma(\sum_{z=1}^T (n_{d,z} + \alpha_z))} = \frac{\Gamma(n_{d_{di}, z_{di}} + \alpha_{z_{di}}) \times \left[\prod_{d=1}^D \prod_{z=1}^T \Gamma(n_{d,z} + \alpha_z) \right]_{-d_{di}, z_{di}}}{\Gamma(\sum_{z=1}^T (n_{d_{di}, z} + \alpha_z)) \times \prod_{d \neq d_{di}}^D \Gamma(\sum_{z=1}^T (n_{d,z} + \alpha_z))}$$

Step 8: (3.7)/(3.6), 借助 $\Gamma(x+1) = x\Gamma(x)$ 可得:

$$\frac{\prod_{d=1}^D \frac{\prod_{z=1}^T \Gamma(n_{d,z} + \alpha_z)}{\Gamma(\sum_{z=1}^T (n_{d,z} + \alpha_z))}}{\left[\prod_{d=1}^D \frac{\prod_{z=1}^T \Gamma(n_{d,z} + \alpha_z)}{\Gamma(\sum_{z=1}^T (n_{d,z} + \alpha_z))} \right]_{-di}} = \frac{n_{d_{di}, z_{di}} + \alpha_{z_{di}} - 1}{\sum_{z=1}^T (n_{d_{di}, z} + \alpha_z) - 1}$$

Step 9: 将(3.8)(3.5)(3.2)代入到(3.1)可得

$$\begin{aligned} P(z_{di} | \mathbf{w}, \mathbf{t}, \mathbf{z}_{-di}, \alpha, \beta, \Psi) &\propto \frac{P(\mathbf{z}, \mathbf{w}, \mathbf{t} | \alpha, \beta, \Psi)}{P(\mathbf{z}_{-di}, \mathbf{w}_{-di}, \mathbf{t}_{-di} | \alpha, \beta, \Psi)} = P(t_{di} | \psi_{z_{di}}) \times \frac{n_{z_{di}, w_{di}} + \beta_{w_{di}} - 1}{\sum_{v=1}^V (n_{z_{di}, v} + \beta_v) - 1} \times \frac{n_{d_{di}, z_{di}} + \alpha_{z_{di}} - 1}{\sum_{z=1}^T (n_{d_{di}, z} + \alpha_z) - 1} \\ &= \frac{(1 - t_{di}) \psi_{z_{di}}^{1-t_{di}} t_{di}^2 \psi_{z_{di}}^{2-t_{di}}}{B(\psi_{z_{di}}^1 - 1, \psi_{z_{di}}^2 - 1)} \times \frac{n_{z_{di}, w_{di}} + \beta_{w_{di}} - 1}{\sum_{v=1}^V (n_{z_{di}, v} + \beta_v) - 1} \times \frac{n_{d_{di}, z_{di}} + \alpha_{z_{di}} - 1}{\sum_{z=1}^T (n_{d_{di}, z} + \alpha_z) - 1} \end{aligned}$$

其中 $B(\alpha, \beta) = \frac{\Gamma(\alpha)\Gamma(\beta)}{\Gamma(\alpha+\beta)}$ 。我们可以利用上式对每个 z_{di} 进行抽样, 当迭代次数足够大时, 抽样结果趋于稳定。

$$\text{LDA 中 Gibbs Sampling 中 } P(z_{di} | \mathbf{w}, \mathbf{z}_{-di}, \alpha, \beta) \propto \frac{n_{z_{di}, w_{di}} + \beta_{w_{di}} - 1}{\sum_{v=1}^V (n_{z_{di}, v} + \beta_v) - 1} \times \frac{n_{d_{di}, z_{di}} + \alpha_{z_{di}} - 1}{\sum_{z=1}^T (n_{d_{di}, z} + \alpha_z) - 1}$$

对比 LDA Gibbs Sampling 发现, 模型中加入时间信息后, 对 z_{di} 抽样时依据的概率分布做了一些改变, 相当于在 LDA 的基础上增加了一个因子。

当对 z_{di} 的抽样完成后，我们可以方便的根据 $n_{z,v}$ 和 $n_{d,z}$ 对 ϕ_z 与 θ_d 进行估计
例如，对于第 z 个 topic 的 topic-words 分布，可以用：

$$\phi_z^v = \frac{n_{z,v} + \beta_v - 1}{\sum_{v=1}^V (n_{z,v} + \beta_v) - 1}$$

求得 $\phi_z = (\phi_z^1, \dots, \phi_z^V)$

D. Quick Derivation

对于 TOT 的 Gibbs Sampling, 我们要求的是

$$P(z_{di} | \mathbf{w}, \mathbf{t}, \mathbf{z}_{-di}, \alpha, \beta, \Psi)$$

根据 Bayes Rule, 上式可以写作：

$$P(z_{di} | \mathbf{w}, \mathbf{t}, \mathbf{z}_{-di}, \alpha, \beta, \Psi) = \frac{P(\mathbf{w}, \mathbf{t}, \mathbf{z}, \alpha, \beta, \Psi)}{P(\mathbf{w}, \mathbf{t}, \mathbf{z}_{-di}, \alpha, \beta, \Psi)}$$

根据 Graphical Model, w_{di}, t_{di} 都是由 z_{di} 生成的，如果不考虑 z_{di} 则无法考虑 w_{di}, t_{di} ，因此：

$$P(z_{di} | \mathbf{w}, \mathbf{t}, \mathbf{z}_{-di}, \alpha, \beta, \Psi) \propto \frac{P(\mathbf{w}, \mathbf{t}, \mathbf{z}, \alpha, \beta, \Psi)}{P(\mathbf{z}_{-di}, \mathbf{w}_{-di}, \mathbf{t}_{-di}, \alpha, \beta, \Psi)} = \frac{P(\mathbf{w}, \mathbf{t}, \mathbf{z} | \alpha, \beta, \Psi)}{P(\mathbf{z}_{-di}, \mathbf{w}_{-di}, \mathbf{t}_{-di} | \alpha, \beta, \Psi)}$$

根据 d-separate 可以判定对于不同的 i, j : z_{di}, w_{di}, t_{di} 与 z_{dj}, w_{dj}, t_{dj} 在条件 α, β, Ψ 下是独立的。因此，上式右边可以拆为各项连乘的形式，分子分母消去公共项，只剩 $P(z_{di}, w_{di}, t_{di} | \alpha, \beta, \Psi)$ ，即

$$P(z_{di} | \mathbf{w}, \mathbf{t}, \mathbf{z}_{-di}, \alpha, \beta, \Psi) \propto P(z_{di}, w_{di}, t_{di} | \alpha, \beta, \Psi)$$

又由于 z_{di}, w_{di}, t_{di} 与 z_{dj}, w_{dj}, t_{dj} 实际上在条件 $\Phi, \Theta, \alpha, \beta, \Psi$ 下也是独立的，同理可得

$$P(z_{di} | \mathbf{w}, \mathbf{t}, \mathbf{z}_{-di}, \Phi, \Theta, \alpha, \beta, \Psi) \propto P(z_{di}, w_{di}, t_{di} | \Phi, \Theta, \alpha, \beta, \Psi)$$

根据 Graphical Model $P(z_{dj}, w_{dj}, t_{dj} | \Phi, \Theta, \alpha, \beta, \Psi)$ 可以写作：

$$P(z_{di}, w_{di}, t_{di} | \Phi, \Theta, \alpha, \beta, \Psi) = P(w_{di} | z_{di}, \Phi, \beta) P(t_{di} | z_{di}, \Psi) P(z_{di} | \Theta, \alpha)$$

由于抽 w_{di} 和抽 z_{di} 都满足多项式分布，抽 t_{di} 满足 beta 分布，于是有：

$$P(w_{di} | z_{di}, \Phi, \beta) = \frac{n_{z_{di}, w_{di}} + \beta_{w_{di}}}{\sum_{v=1}^V (n_{z_{di}, v} + \beta_v)}$$

$$P(z_{di} | \Theta, \alpha) = \frac{n_{d_{di}, z_{di}} + \alpha_{z_{di}}}{\sum_{z=1}^T (n_{d_{di}, z} + \alpha_z)}$$

$$P(t_{di} | z_{di}, \Psi) = \frac{(1 - t_{di})^{\psi_{z_{di}}^1 - 1} t_{di}^{\psi_{z_{di}}^2 - 1}}{B(\psi_{z_{di}}^1 - 1, \psi_{z_{di}}^2 - 1)}$$

于是得到 $P(z_{di} | \mathbf{w}, \mathbf{t}, \mathbf{z}_{-di}, \alpha, \beta, \Psi) \propto \frac{(1 - t_{di})^{\psi_{z_{di}}^1 - 1} t_{di}^{\psi_{z_{di}}^2 - 1}}{B(\psi_{z_{di}}^1 - 1, \psi_{z_{di}}^2 - 1)} \times \frac{n_{z_{di}, w_{di}} + \beta_{w_{di}}}{\sum_{v=1}^V (n_{z_{di}, v} + \beta_v)} \times \frac{n_{d_{di}, z_{di}} + \alpha_{z_{di}}}{\sum_{z=1}^T (n_{d_{di}, z} + \alpha_z)}$

对于 LDA, 推导过程同上，只是我们无需考虑 t_{di} ，于是 $P(z_{di} | \mathbf{w}, \mathbf{z}_{-di}, \alpha, \beta, \Psi) = \frac{n_{z_{di}, w_{di}} + \beta_{w_{di}}}{\sum_{v=1}^V (n_{z_{di}, v} + \beta_v)} \times \frac{n_{d_{di}, z_{di}} + \alpha_{z_{di}}}{\sum_{z=1}^T (n_{d_{di}, z} + \alpha_z)}$

E. References

- [1] D. Blei, A. Ng, and M. Jordan. Latent Dirichlet allocation. Journal of Machine Learning Research, 3:993–1022, 2003.
- [2] Xuerui Wang, Andrew McCallum. Topics over Time: A Non-Markov Continuous-Time Model of Topical Trends. KDD'06 August 20–23, 2006, Philadelphia, Pennsylvania, USA