

# 贝叶斯统计

## 贝叶斯计算

---

陈垚翰

安徽大学 大数据与统计学院



安徽大学  
Anhui University

# 后验分布的计算和抽样

- 后验分布可以一般表示为

$$\pi(\theta | \mathbf{x}) = \frac{\pi(\theta)p(\mathbf{x} | \theta)}{\int_{\Theta} \pi(\theta)p(\mathbf{x} | \theta)d\theta}$$

- 分母中的积分  $\int_{\Theta} \pi(\theta)p(\mathbf{x} | \theta)d\theta$  难以计算
- 从  $\pi(\theta | \mathbf{x})$  中抽样  $\{\theta^{(i)}\}_{i=1}^m$ , 并根据大数定律计算

$$\mathbb{E}[g(\theta) | \mathbf{x}] \approx \frac{1}{m} \sum_{i=1}^m g(\theta^{(i)})$$

# 马氏链

- 马氏性: 链  $\{\theta^{(0)}, \theta^{(1)}, \dots\}$  具有马氏性是指  $\theta^{(t+1)}$  只依赖于  $\theta^{(t)}$ , 而不依赖于  $\{\theta^{(0)}, \theta^{(1)}, \dots, \theta^{(t-1)}\}$  ( $t \geq 1$ )。
- 马氏链的生成: 给定初始值  $\theta^{(0)}$ , 通过条件分布

$$p\left(\theta \mid \theta^{(t)}\right), t = 1, 2, \dots$$

产生新的随机数  $\theta^{(t+1)}$ , 其中  $p(\cdot \mid \cdot)$  又称为转移核。

# 马氏链

有限状态离散形式的马氏链 (Discrete Markov Chain with finite state space):

- 状态空间有  $K$  个状态, 记为  $1, \dots, K$ 。转移核构成如下转移概率矩阵

$$\mathbf{P}^{[t-1,t]} = \begin{bmatrix} p_{1,1}^{[t-1,t]} & \cdots & p_{1,K}^{[t-1,t]} \\ \vdots & \cdots & \vdots \\ p_{K,1}^{[t-1,t]} & \cdots & p_{K,K}^{[t-1,t]} \end{bmatrix} \quad \text{简记为 } \mathbf{P} = \begin{bmatrix} p_{1,1} & \cdots & p_{1,K} \\ \vdots & \vdots & \vdots \\ p_{K,1} & \cdots & p_{K,K} \end{bmatrix}$$

其中,  $p_{i,j}^{[t-1,t]} = \mathbf{P}(\theta^{(t)} = j \mid \theta^{(t-1)} = i)$ 。

- $\sum_j p_{i,j}^{[t-1,t]} = 1$ .

令

$$\mathbf{P}^{[2]} := \begin{bmatrix} p_{1,1}^{[2]} & \cdots & p_{1,K}^{[2]} \\ \vdots & \vdots & \vdots \\ p_{K,1}^{[2]} & \cdots & p_{K,K}^{[2]} \end{bmatrix}$$

其中,  $p_{ij}^{[2]} = \mathbf{P}(\theta^{(t+2)} = j \mid \theta^{(t)} = i)$  状态  $i$  经 2 步转移至  $j$  的概率。

- 注意到

$$(\theta^{(2)} = j \mid \theta^{(0)} = i) = \bigcup_k (\theta^{(2)} = j, \theta^{(1)} = k \mid \theta^{(0)} = i).$$

# 马氏链

由条件概率公式和马氏性可知

$$\begin{aligned}P\left(\theta^{(2)} = j \mid \theta^{(0)} = i\right) &= \sum_{k=1}^K P\left(\theta^{(2)} = j, \theta^{(1)} = k \mid \theta^{(0)} = i\right) \\&= \sum_{k=1}^K P\left(\theta^{(2)} = j \mid \theta^{(1)} = k, \theta^{(0)} = i\right) \\&\quad \times P\left(\theta^{(0)} = i\right) \\&= \sum_{k=1}^K P\left(\theta^{(2)} = j \mid \theta^{(1)} = k\right) \\&\quad \times P\left(\theta^{(0)} = i\right).\end{aligned}$$

所以  $p_{i,j}^{[2]} = \sum_{k=1}^K p_{i,k} \times p_{k,j}$ , 即  $\mathbf{P}^{[2]} = \mathbf{P} \times \mathbf{P} = \mathbf{P}^2$ 。

可以推广至一般情形：

$$\left(\theta^{(m+n)} = j \mid \theta^{(0)} = i\right) = \bigcup_k \left(\theta^{(m+n)} = j, \theta^{(n)} = k \mid \theta^{(0)} = i\right)$$

$$\mathbf{P}\left(\theta^{(m+n)} = j \mid \theta^{(0)} = i\right) = \sum_{k=1}^K \mathbf{P}\left(\theta^{(m+n)} = j, \theta^{(n)} = k \mid \theta^{(0)} = i\right).$$

$$\mathbf{P}\left(\theta^{(m+n)} = j \mid \theta^{(0)} = i\right) = \sum_k \left\{ \mathbf{P}\left(\theta^{(m+n)} = j \mid \theta^{(n)} = k\right) \right. \\ \left. \times \mathbf{P}\left(\theta^{(n)} = k \mid \theta^{(0)} = i\right) \right\}.$$

$$p_{i,j}^{[m+n]} = \sum_{k=1}^K p_{i,k}^{[m]} \times p_{k,j}^{[n]}$$

$$\mathbf{P}^{[m+n]} = \mathbf{P}^{[m]} \times \mathbf{P}^{[n]}$$

$$\mathbf{P}^{[n]} = \mathbf{P}^n$$

如果以下极限存在,则存在一种稳定的状态

$$\begin{aligned} \lim_{t \rightarrow \infty} \mathbf{I} \times \mathbf{P}^t &= \lim_{t \rightarrow \infty} \mathbf{P}^t \\ &= \begin{bmatrix} \pi_1 & \dots & \pi_K \\ \vdots & \vdots & \vdots \\ \pi_1 & \dots & \pi_K \end{bmatrix}. \end{aligned}$$



# 马氏链

如果长期稳定的状态存在

$$\mathbf{P}^{[t+1]} = \mathbf{P}^{[t]} \times \mathbf{P}$$

则同时在等式两边取极限有

$$\begin{bmatrix} \pi_1 & \dots & \pi_K \\ \vdots & \vdots & \vdots \\ \pi_1 & \dots & \pi_K \end{bmatrix} = \begin{bmatrix} \pi_1 & \dots & \pi_K \\ \vdots & \vdots & \vdots \\ \pi_1 & \dots & \pi_K \end{bmatrix} \times \mathbf{P}.$$

每一行可以表示为

$$\boldsymbol{\pi} = \boldsymbol{\pi} \times \mathbf{P}$$

也称之为稳态方程 (steady state equation)。

- 平稳性(收敛性): 链的平稳性是指, 当  $t \rightarrow \infty$  时, 马氏链  $\{\theta^0, \theta^{(1)}, \theta^{(2)}, \dots, \}$  依分布收敛到某个概率分布, 此分布称为平稳分布(stationary distribution)。
- 正常返性: 状态  $i$  是正常返的, 如果

$$M_i = E [T_i] < \infty,$$

其中  $T_i = \inf \{n \geq 1 : \theta^{(n)} = i \mid \theta^{(0)} = i\}$ 。

- 非周期性: 令

$$k = \gcd \left\{ n : P \left( \theta^{(n)} = i \mid \theta^{(0)} = i \right) > 0 \right\},$$

其中,  $\gcd$  表示最大公约数。如果  $\forall i$  都有  $k = 1$ , 则称马氏链是非周期的 (aperiodic)。

- 遍历性: 如果一个马氏链的状态  $i$  是非周期的且正常返的, 则称  $i$  是遍历的, 如果马氏链的所有状态都是遍历的, 则称马氏链是遍历的。
- 不可约性: 遍历的马氏链称为不可约的 (irreducible)。

## 定理

设  $\{\theta^{(0)}, g \geq 0\}$  为不可约的非周期的马氏链,  $\pi$  为其平稳分布,  $\pi_0$  为初始分布, 则

$$\pi_t \rightarrow \pi, t \rightarrow \infty$$

其中  $\pi_t$  为马氏链在时刻  $t$  的分布。

# 马氏链

例子: 不可约马氏链的平稳分布

$$\mathbf{P} = \begin{bmatrix} 0.35 & 0.35 & 0.10 & 0.10 & 0.10 \\ 0.15 & 0.55 & 0.10 & 0.10 & 0.10 \\ 0.15 & 0.15 & 0.10 & 0.20 & 0.40 \\ 0.15 & 0.15 & 0.40 & 0.10 & 0.20 \\ 0.15 & 0.15 & 0.20 & 0.40 & 0.10 \end{bmatrix}$$

$$\mathbf{P}^{[2^5]} = \begin{bmatrix} 0.187500 & 0.312500 & 0.166667 & 0.166667 & 0.166667 \\ 0.187500 & 0.312500 & 0.166667 & 0.166667 & 0.166667 \\ 0.187500 & 0.312500 & 0.166667 & 0.166667 & 0.166667 \\ 0.187500 & 0.312500 & 0.166667 & 0.166667 & 0.166667 \\ 0.187500 & 0.312500 & 0.166667 & 0.166667 & 0.166667 \end{bmatrix}$$

定理(马氏链大数定律)

设  $\{\theta^{(1)}, \theta^{(2)}, \dots, \theta^{(n)}, \dots\}$  为遍历的平稳分布为  $\pi$  的马氏链, 则  $\theta^{(n)}$  依分布收敛到  $\pi$  的随机变量  $\theta$ , 且对任意连续函数  $g$ , 当  $E_{\pi}[g(\theta)]$  存在时, 有

$$\frac{1}{n} \sum_{i=1}^n g(\theta^{(i)}) \rightarrow E_{\pi}[g(\theta)], \quad n \rightarrow \infty.$$

# 马氏链

---

不可约的马氏链有平稳分布; 而对于平稳分布, 是否存在相应的不可约马氏链? 或者相应的转移核?

# 马氏链

不可约的马氏链有平稳分布；而对于平稳分布，是否存在相应的不可约马氏链？或者相应的转移核？

$$\begin{aligned} q_{ij} &= P\left(\theta^{(t)} = j \mid \theta^{(t+1)} = i\right) \\ &= \frac{P\left(\theta^{(t)} = j, \theta^{(t+1)} = i\right)}{P\left(\theta^{(t+1)} = i\right)} \\ &= \frac{P\left(\theta^{(t)} = j\right) P\left(\theta^{(t+1)} = i \mid \theta^{(t)} = j\right)}{P\left(\theta^{(t+1)} = i\right)} \end{aligned}$$



# 马氏链

不可约的马氏链有平稳分布; 而对于平稳分布, 是否存在相应的不可约马氏链? 或者相应的转移核?

$$\begin{aligned} q_{i,j} &= P\left(\theta^{(t)} = j \mid \theta^{(t+1)} = i\right) \\ &= \frac{P\left(\theta^{(t)} = j, \theta^{(t+1)} = i\right)}{P\left(\theta^{(t+1)} = i\right)} \\ &= \frac{P\left(\theta^{(t)} = j\right) P\left(\theta^{(t+1)} = i \mid \theta^{(t)} = j\right)}{P\left(\theta^{(t+1)} = i\right)} \end{aligned}$$

在稳态时,

$$q_{i,j} = \frac{\pi_j p_{j,i}}{\pi_i}$$

- 当  $\forall i, j$  都有  $p_{ij} = q_{ij}$ , 则称相应的马氏链是时序可逆的 (time reversible), 且

$$\pi_i p_{i,j} = \pi_j p_{j,i}.$$

上述等式也称之为“detailed balance”条件。

## 定理

满足  $\pi_i p_{i,j} = \pi_j p_{j,i}$  的转移核  $p_{ij}$  有平稳分布  $\pi$ 。

$$\begin{aligned}\sum_i \pi_i p_{i,j} &= \sum_i \pi_j p_{j,i} \\ &= \pi_j \sum_i p_{j,i} \\ &= \pi_j \sum_j p_{i,j} \\ &= \pi_j\end{aligned}$$

# Gibbs 抽样

- 从后验分布  $\pi(\boldsymbol{\theta} | \mathbf{x})$  中对  $\boldsymbol{\theta}$  分块抽样,  $\boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_p)$ 。

$$\pi(\theta_j | \theta_{-j}, \mathbf{x}) = \frac{\pi(\theta_1, \dots, \theta_{j-1}, \theta_j, \theta_{j+1}, \dots, \theta_p | \mathbf{x})}{\int \pi(\theta_1, \dots, \theta_{j-1}, \theta_j, \theta_{j+1}, \dots, \theta_p | \mathbf{x}) d\theta_j}$$

称之为 full conditional distribution,

$$\theta_{-j} = (\theta_1, \dots, \theta_{j-1}, \theta_{j+1}, \dots, \theta_p)$$

- Gibbs 抽样: 根据 full conditional distribution 构造马氏链。

# Gibbs 抽样

1. 给定初始值  $\theta_1^{(0)}, \theta_2^{(0)}, \dots, \theta_p^{(0)}$
2. 对  $t = 0, 1, 2, \dots$ 
  - a) 从条件分布  $\pi(\theta_1 | \theta_2^{(t)}, \dots, \theta_p^{(t)}, \mathbf{x})$  中产生  $\theta_1^{(t+1)}$
  - b) 从条件分布  $\pi(\theta_2 | \theta_1^{(t+1)}, \theta_3^{(t)}, \dots, \theta_p^{(t)}, \mathbf{x})$  产生  $\theta_2^{(t+1)}$
  - .....
  - c) 从条件分布  $\pi(\theta_p | \theta_1^{(t+1)}, \theta_2^{(t+1)}, \dots, \theta_p^{(t+1)}, \mathbf{x})$  产生  $\theta_p^{(t+1)}$

重复 2. 中的 a), b) 和 c) 生成马氏链  $\boldsymbol{\theta}^{(0)}, \boldsymbol{\theta}^{(1)}, \dots, \boldsymbol{\theta}^{(t)}, \dots$

由马氏链大数定律

$$\frac{1}{n} \sum_{t=1}^n g(\boldsymbol{\theta}^{(t)}) \rightarrow \int g(\boldsymbol{\theta}) \pi(\boldsymbol{\theta} | \mathbf{x}) d\boldsymbol{\theta}$$

# Gibbs 抽样

一个例子:

目标是从  $p(\theta_1, \theta_2) \propto e^{-\theta_1 \theta_2} \mathbf{1}\{\theta_1, \theta_2 \in (0, c)\}$  中抽样

- $p(\theta_1, \theta_2)$  具有对称结构, 且

$$p(\theta_1 | \theta_2) \propto p(\theta_1, \theta_2) \propto e^{-\theta_1 \theta_2} \mathbf{1}(0 < \theta_1 < c) \propto \text{Exp}(\theta_1 | \theta_2) \mathbf{1}(\theta_1 < c)$$



即  $p(\theta_1 | \theta_2)$  在  $(0, c)$  上是截尾的指数分布, 记作  $\text{TExp}(\theta_2, (0, c))$ 。  
根据对称性,  $p(\theta_2 | \theta_1)$  也是在  $(0, c)$  上是截尾的指数分布,  
记作  $\text{TExp}(\theta_1, (0, c))$ 。

# Gibbs 抽样

在上述例子中, Gibbs 抽样步骤如下:

0. 初始化  $\theta_1^{(0)}, \theta_2^{(0)} \in (0, c)$
1. 从  $\text{TExp}(\theta_2^{(0)}, (0, c))$  中抽  $\theta_1^{(1)}$ , 然后从  $\text{TExp}(\theta_1^{(1)}, (0, c))$  中抽  $\theta_2^{(1)}$
2. 从  $\text{TExp}(\theta_2^{(1)}, (0, c))$  中抽  $\theta_1^{(2)}$ , 然后从  $\text{TExp}(\theta_1^{(2)}, (0, c))$  中抽  $\theta_2^{(2)}$
- ...
- n. 从  $\text{TExp}(\theta_2^{(n-1)}, (0, c))$  中抽  $\theta_1^{(n)}$ , 然后从  $\text{TExp}(\theta_1^{(n)}, (0, c))$  中抽  $\theta_2^{(n)}$ .

# Gibbs 抽样





# Metropolis-Hastings 算法

---

当在 Gibbs 抽样中,不易从条件分布中抽样时怎么办?

# Metropolis-Hastings 算法

当在 Gibbs 抽样中,不易从条件分布中抽样时怎么办?

- 选择合适的转移核构造马氏链  $\boldsymbol{\theta}^{(0)}, \boldsymbol{\theta}^{(1)}, \dots, \boldsymbol{\theta}^{(t)}, \dots$ , 使得该马氏链有相应的平稳分布  $\pi(\boldsymbol{\theta})$  或者  $\pi(\boldsymbol{\theta} | \mathbf{x})$ 。
- 转移核用以由  $\boldsymbol{\theta}^{(t)}$  生成  $\boldsymbol{\theta}^{(t+1)}$ 。
- 稳态方程  $\boldsymbol{\pi} = \boldsymbol{\pi} \times \mathbf{P}$  在连续状态空间  $\Theta$  的形式

$$\int_A \pi(\boldsymbol{\theta}) d\boldsymbol{\theta} = \int \pi(\boldsymbol{\theta}) P(\boldsymbol{\theta}, A) d\boldsymbol{\theta}$$

其中  $\boldsymbol{\theta} \in \Theta$  且  $A \subset \Theta$  是  $\Theta$  的可测子集,  $P(\boldsymbol{\theta}, A)$  是转移核。

- 记  $q(\boldsymbol{\theta}, \boldsymbol{\theta}')$  为由  $\boldsymbol{\theta}$  生成  $\boldsymbol{\theta}'$  的建议分布 (proposal distribution)。

# Metropolis-Hastings 算法

## 定理

如果 proposal distribution  $q(\boldsymbol{\theta}, \boldsymbol{\theta}')$  满足 “detailed balance” 条件,

$$\pi(\boldsymbol{\theta}) \times q(\boldsymbol{\theta}, \boldsymbol{\theta}') = \pi(\boldsymbol{\theta}') \times q(\boldsymbol{\theta}', \boldsymbol{\theta}) \text{ 对任意 } \boldsymbol{\theta}, \boldsymbol{\theta}'$$

则

$$P(\boldsymbol{\theta}, A) = \int_{\{A \cap \{\boldsymbol{\theta}' \neq \boldsymbol{\theta}\}\}} q(\boldsymbol{\theta}, \boldsymbol{\theta}') d\boldsymbol{\theta}' + r(\boldsymbol{\theta}) \delta_A(\boldsymbol{\theta})$$

且  $\pi(\boldsymbol{\theta})$  是以  $P(\boldsymbol{\theta}, A)$  为转移核的马氏链的平稳分布。

其中,  $r(\boldsymbol{\theta}) = 1 - \int_{\{\boldsymbol{\theta}' \neq \boldsymbol{\theta}\}} q(\boldsymbol{\theta}, \boldsymbol{\theta}') d\boldsymbol{\theta}'$  是停留在  $\boldsymbol{\theta}$  的概率

$$\delta_A(\boldsymbol{\theta}) = \begin{cases} 1 & \text{if } \boldsymbol{\theta} \in A \\ 0 & \text{if } \boldsymbol{\theta} \notin A \end{cases}$$

## 证明

$$\begin{aligned}& \int \pi(\boldsymbol{\theta}) P(\boldsymbol{\theta}, A) d\boldsymbol{\theta} \\&= \iint_{\{A \cap \{\boldsymbol{\theta}' \neq \boldsymbol{\theta}\}\}} \pi(\boldsymbol{\theta}) q(\boldsymbol{\theta}, \boldsymbol{\theta}') d\boldsymbol{\theta}' d\boldsymbol{\theta} + \int \pi(\boldsymbol{\theta}) r(\boldsymbol{\theta}) \delta_A(\boldsymbol{\theta}) d\boldsymbol{\theta} \\&= \int_A \int_{\{\boldsymbol{\theta} \neq \boldsymbol{\theta}'\}} \pi(\boldsymbol{\theta}) q(\boldsymbol{\theta}, \boldsymbol{\theta}') d\boldsymbol{\theta} d\boldsymbol{\theta}' + \int_A \pi(\boldsymbol{\theta}) r(\boldsymbol{\theta}) d\boldsymbol{\theta} \\&= \int_A \int_{\{\boldsymbol{\theta} \neq \boldsymbol{\theta}'\}} \pi(\boldsymbol{\theta}') q(\boldsymbol{\theta}', \boldsymbol{\theta}) d\boldsymbol{\theta} d\boldsymbol{\theta}' + \int_A \pi(\boldsymbol{\theta}) r(\boldsymbol{\theta}) d\boldsymbol{\theta} \\&= \int_A \pi(\boldsymbol{\theta}') (1 - r(\boldsymbol{\theta}')) d\boldsymbol{\theta}' + \int_A \pi(\boldsymbol{\theta}) r(\boldsymbol{\theta}) d\boldsymbol{\theta} \\&= \int_A \pi(\boldsymbol{\theta}') d\boldsymbol{\theta}' = \int_A \pi(\boldsymbol{\theta}) d\boldsymbol{\theta}\end{aligned}$$

# Metropolis-Hastings 算法

- “detailed balance” 条件,

$$\pi(\boldsymbol{\theta}) \times q(\boldsymbol{\theta}, \boldsymbol{\theta}') = \pi(\boldsymbol{\theta}') \times q(\boldsymbol{\theta}', \boldsymbol{\theta}) \text{ 对任意 } \boldsymbol{\theta}, \boldsymbol{\theta}'$$

是 Metropolis-Hastings 算法的关键。

- 但不是所有的 proposal distribution  $q(\boldsymbol{\theta}, \boldsymbol{\theta}')$  都满足 “detailed balance” 条件, 如何找到 proposal distribution 满足 “detailed balance” 条件。
- 令

$$\alpha(\boldsymbol{\theta}, \boldsymbol{\theta}') = \min \left[ 1, \frac{\pi(\boldsymbol{\theta}') q(\boldsymbol{\theta}', \boldsymbol{\theta})}{\pi(\boldsymbol{\theta}) q(\boldsymbol{\theta}, \boldsymbol{\theta}')} \right]$$

则  $\alpha(\boldsymbol{\theta}, \boldsymbol{\theta}') \times q(\boldsymbol{\theta}, \boldsymbol{\theta}')$  一定满足 “detailed balance” 条件。

## 证明

$$\begin{aligned}\pi(\theta) \times \alpha(\theta, \theta') \times q(\theta, \theta') &= \pi(\theta) \times \min \left[ 1, \frac{\pi(\theta') q(\theta', \theta)}{\pi(\theta) q(\theta, \theta')} \right] \times q(\theta, \theta') \\ &= \min [\pi(\theta) q(\theta, \theta'), \pi(\theta') q(\theta', \theta)] \\ &= \pi(\theta') \times \min \left[ 1, \frac{\pi(\theta) q(\theta, \theta')}{\pi(\theta') q(\theta', \theta)} \right] \times q(\theta', \theta) \\ &= \pi(\theta') \times \alpha(\theta', \theta) \times q(\theta', \theta)\end{aligned}$$

# Metropolis-Hastings 算法

当状态空间有  $K$  个状态, 记为  $1, \dots, K$ ,

- 马氏链有转移核  $p_{ij}$
- 平稳分布为  $\boldsymbol{\pi} = (\pi_1, \dots, \pi_K)$
- 对每个状态  $i$  和 状态  $j$ , 定义

$$\alpha_{i,j} = \min \left[ 1, \frac{\pi_j p_{j,i}}{\pi_i p_{i,j}} \right].$$

- 对每个状态  $i$  和  $j \neq i$ , 定义  $p'_{i,j} = \alpha_{i,j} p_{i,j}$
- 定义

$$p'_{i,i} = 1 - \sum_{j \neq i} p'_{i,j}$$

则  $\boldsymbol{\pi}$  是以  $p'_{i,j}$  转移核的平稳分布。



## 证明

注意到

$$\begin{aligned}\pi_i p'_{i,j} &= \pi_i \alpha_{i,j} p_{i,j} \\ &= \pi_i \times \min \left[ 1, \frac{\pi_j p_{j,i}}{\pi_i p_{i,j}} \right] \times p_{i,j} \\ &= \min [\pi_j p_{j,i}, \pi_i p_{i,j}]\end{aligned}$$

同时

$$\begin{aligned}\pi_j p'_{j,i} &= \pi_j \alpha_{j,i} p_{j,i} \\ &= \pi_j \times \min \left[ 1, \frac{\pi_i p_{i,j}}{\pi_j p_{j,i}} \right] \times p_{j,i} \\ &= \min [\pi_j p_{j,i}, \pi_i p_{i,j}]\end{aligned}$$

所以  $p'_{i,j}$  满足“detailed balance”条件, 即  $\pi$  是以  $p'_{i,j}$  为转移核的平稳分布。

# Metropolis-Hastings 算法

Metropolis-Hastings 算法的主要步骤如下：

1. 初始化  $\theta^{(0)}$
2. 对于  $t = 1, 2, \dots$ 
  - a) 由  $q(\theta^{(t-1)}, \theta')$  产生  $\theta'$
  - b) 计算接受概率  $\alpha(\theta^{(t-1)}, \theta')$
  - c) 从均匀分布  $U(0, 1)$  中生成  $u$
  - d) 如果  $u < \alpha(\theta^{(t-1)}, \theta')$  则令  $\theta^{(t)} = \theta'$ ，  
否则令  $\theta^{(t)} = \theta^{(t-1)}$

重复 2. 中的 a), b), c) 和 d) 生成马氏链  $\theta^{(0)}, \theta^{(1)}, \dots, \theta^{(t)}, \dots$

# Metropolis-Hastings 算法

---

如果将  $\pi(\boldsymbol{\theta} | \mathbf{x})$  作为平稳分布, 则

$$\alpha(\boldsymbol{\theta}, \boldsymbol{\theta}') = \min \left[ 1, \frac{\pi(\boldsymbol{\theta}' | \mathbf{x}) q(\boldsymbol{\theta}', \boldsymbol{\theta})}{\pi(\boldsymbol{\theta} | \mathbf{x}) q(\boldsymbol{\theta}, \boldsymbol{\theta}')} \right]$$

因此无需计算  $\int_{\Theta} \pi(\boldsymbol{\theta}) p(\mathbf{x} | \boldsymbol{\theta}) d\boldsymbol{\theta}$ , 其中  $\pi(\boldsymbol{\theta})$  表示先验分布。

# Metropolis-Hastings 算法：一个例子

考虑如下平稳分布

$$\pi(\theta) = \frac{\exp(-\theta^2) (2 + \sin(5\theta) + \sin(2\theta))}{\int_{-\infty}^{\infty} \exp(-\theta^2) (2 + \sin(5\theta) + \sin(2\theta)) d\theta}$$

利用 Metropolis-Hastings 算法, 可以在不用计算

$$\int_{-\infty}^{\infty} \exp(-\theta^2) (2 + \sin(5\theta) + \sin(2\theta)) d\theta$$

的条件下从  $\pi(\theta)$  中抽样。

# Metropolis-Hastings 算法：一个例子

- 选用正态分布作为 proposal distribution

$$\theta' | \theta \sim \text{Normal}(\theta, \sigma^2)$$


- 计算接受概率

$$\begin{aligned}\alpha(\theta, \theta') &= \min \left[ 1, \frac{\pi(\theta')}{\pi(\theta)} \times \frac{q(\theta, \theta')}{q(\theta', \theta)} \right] \\ &= \min \left[ 1, \frac{\pi(\theta')}{\pi(\theta)} \right]\end{aligned}$$



其中，

$$\frac{\pi(\theta')}{\pi(\theta)} = \frac{\exp(-\theta'^2) (2 + \sin(5\theta') + \sin(2\theta'))}{\exp(-\theta^2) (2 + \sin(5\theta) + \sin(2\theta))}$$



# Metropolis-Hastings 算法：一个例子




$\sigma=1$



$\sigma=0.025$



$\sigma=50$



# Proposal Distribution 的选取

- 随机游走形式的 proposal distribution,  $q(\boldsymbol{\theta}, \boldsymbol{\theta}') = q_1(\boldsymbol{\theta}' - \boldsymbol{\theta})$ , 其中  $q_1(\cdot)$  是关于 0 的对称函数。

$$\begin{aligned}\alpha(\boldsymbol{\theta}, \boldsymbol{\theta}') &= \min \left[ 1, \frac{\pi(\boldsymbol{\theta}') q(\boldsymbol{\theta}', \boldsymbol{\theta})}{\pi(\boldsymbol{\theta}) q(\boldsymbol{\theta}, \boldsymbol{\theta}')} \right] \\ &= \min \left[ 1, \frac{\pi(\boldsymbol{\theta}')}{\pi(\boldsymbol{\theta})} \right]\end{aligned}$$

# Proposal Distribution 的选取

- 独立 proposal distribution,  $q(\boldsymbol{\theta}, \boldsymbol{\theta}') = q_2(\boldsymbol{\theta}')$ , 其中  $q_2(\boldsymbol{\theta}')$  与当前状态  $\boldsymbol{\theta}$  无关。

$$\begin{aligned}\alpha(\boldsymbol{\theta}, \boldsymbol{\theta}') &= \min \left[ 1, \frac{\pi(\boldsymbol{\theta}') q(\boldsymbol{\theta}', \boldsymbol{\theta})}{\pi(\boldsymbol{\theta}) q(\boldsymbol{\theta}, \boldsymbol{\theta}')} \right] \\ &= \min \left[ 1, \frac{\pi(\boldsymbol{\theta}')}{\pi(\boldsymbol{\theta})} \times \frac{q_2(\boldsymbol{\theta})}{q_2(\boldsymbol{\theta}')} \right]\end{aligned}$$



# 贝叶斯计算的应用：Real Business Cycle 模型的估计

- Real Business Cycle (RBC) 模型由 Kydland 和 Prescott (1982) 提出,旨在新古典增长模型(neoclassical growth model)中对不确定性建模,RBC 模型是后续的动态随机一般均衡 (Dynamic Stochastic General Equilibrium, DSGE) 的基础。
- 以 King 和 Rebelo (1999) 中的 RBC 模型为例。
- Social Planner (政府) 考虑如下效用最大化问题

$$\max_{\{C_t, N_t, I_t\}} E \left\{ \sum_{t=0}^{\infty} \beta^t [\ln C_t + \chi \ln (1 - N_t)] \right\},$$

## 满足约束条件

$$C_t + I_t = z_t K_t^\alpha N_t^{1-\alpha} = Y_t$$

$$K_{t+1} = (1 - \delta)K_t + I_t$$

$$\ln z_t = \rho \ln z_{t-1} + \sigma \varepsilon_t, \quad \varepsilon_t \sim \text{IID } N(0, 1),$$

其中

- $C_t$  表示社会总消费需求 ( aggregate consumption ) ;
- $N_t$  表示社会总劳动需求 ( aggregate labor demand ) ;
- $K_t$  表示社会资本总量 ( aggregate capital ) ;
- $I_t$  表示社会投资总量 ( aggregate investment ) ;
- $z_t$  表示技术进步对全要素生产率的冲击 ( total factor productivity (TFP) shocks ), 服从 AR(1) 过程;
- $\delta$  表示资本折旧率。

注意到在约束条件下

$$\max_{\{C_t, N_t, I_t\}} \mathbb{E} \left\{ \sum_{t=0}^{\infty} \beta^t [\ln C_t + \chi \ln (1 - N_t)] \right\}$$

$\Leftrightarrow$

$$\max_{\{K_{t+1}, N_t\}} \mathbb{E} \left\{ \sum_{t=0}^{\infty} \beta^t \left[ \ln \left( z_t K_t^\alpha N_t^{1-\alpha} + (1 - \delta)K_t - K_{t+1} \right) + \chi \ln (1 - N_t) \right] \right\}$$

关于  $K_{t+1}$  的一阶偏导数

$$-\frac{1}{C_t} + \mathbb{E}_t \left\{ \frac{\beta}{C_{t+1}} [\alpha z_{t+1} K_{t+1}^{\alpha-1} N_{t+1}^{1-\alpha} + 1 - \delta] \right\}$$

关于  $N_t$  的一阶偏导数

$$\frac{(1 - \alpha) z_t K_t^\alpha N_t^{-\alpha}}{C_t} - \frac{\chi}{1 - N_t}$$

令关于  $K_{t+1}$  的一阶偏导数和关于  $N_t$  的一阶偏导数分别等于 0, 则有最优一阶条件(欧拉方程):

$$\frac{1}{C_t} = E_t \left\{ \frac{\beta}{C_{t+1}} [\alpha z_{t+1} K_{t+1}^{\alpha-1} N_{t+1}^{1-\alpha} + 1 - \delta] \right\} \quad (1)$$

$$\frac{\chi C_t}{1 - N_t} = (1 - \alpha) z_t K_t^\alpha N_t^{-\alpha} \quad (2)$$

假设全社会拥有资本, 则实际利率和劳动工资分别为

$$R_{kt} = \alpha z_t K_t^{\alpha-1} N_t^{1-\alpha} \quad (3)$$

和

$$w_t = (1 - \alpha) z_t K_t^\alpha N_t^{-\alpha} \quad (4)$$

# 贝叶斯计算的应用：Real Business Cycle 模型的估计

- $\theta = (\alpha, \beta, \delta, \chi, \rho, \sigma)$
- Steady State (稳态): 所有变量没有时序上的动态特征,  $X_t = X$ 。
- 在稳态下令  $z_t = 1$ , 则欧拉方程 (1) 为

$$1 = \beta [\alpha K^{\alpha-1} N^{1-\alpha} + 1 - \delta]. \quad (5)$$

并由 (5) 式可以解出

$$\frac{K}{N} = \left( \frac{\alpha}{1/\beta - (1 - \delta)} \right)^{\frac{1}{1-\alpha}}.$$

因此,在稳态下

$$R_{kt} = \alpha \frac{Y}{K} = \alpha \left( \frac{K}{N} \right)^{\alpha-1}, w_t = (1 - \alpha) \left( \frac{K}{N} \right)^{\alpha}.$$

由  $K_{t+1} = (1 - \delta)K_t + I_t$  可知,在稳态下

$$I = \delta K = \frac{\delta K}{N} N,$$

且

$$Y = \left( \frac{K}{N} \right)^{\alpha} N.$$

有欧拉方程 (2) 可以解得在稳态下

$$\chi = (1 - \alpha) \left( \frac{K}{N} \right)^{\alpha} \frac{1 - N}{C}.$$

做对数线性化, 令  $\hat{X}_t = \ln X_t - \ln X$ 。在 (2) 两边同时取对数并在稳态取全微分

$$(\ln C_t - \ln C) + \frac{e^{\ln N}}{1 - e^{\ln N}} (\ln N_t - \ln N) = (\ln z_t - \ln z) + \alpha (\ln K_t - \ln K) - \alpha (\ln N_t - \ln N)$$

即

$$\hat{C}_t + \frac{N}{1 - N} \hat{N}_t = \hat{z}_t + \alpha \hat{K}_t - \alpha \hat{N}_t.$$

并可以解得

$$\hat{N}_t = \frac{1}{\alpha + \zeta} \hat{z}_t + \frac{\alpha}{\alpha + \zeta} \hat{K}_t - \frac{1}{\alpha + \zeta} \hat{C}_t.$$

其中,  $\zeta \equiv N/(1 - N)$

将  $K_{t+1} = (1 - \delta)K_t + I_t$  代入  $C_t + I_t = z_t K_t^\alpha N_t^{1-\alpha} = Y_t$  并在稳态取全微分

$$\begin{aligned} & dC_t + dK_{t+1} - (1 - \delta)dK_t \\ &= K^\alpha N^{1-\alpha} dz_t + \alpha K^{\alpha-1} N^{1-\alpha} dK_t + (1 - \alpha)K^\alpha N^{-\alpha} dN_t. \end{aligned}$$

注意到  $d \ln x = \frac{1}{x} dx$ , 进而有

$$\begin{aligned} & C\hat{C}_t + K\hat{K}_{t+1} - (1 - \delta)K\hat{K}_t \\ &= K^\alpha N^{1-\alpha} \hat{z}_t + \alpha K^\alpha N^{1-\alpha} \hat{K}_t + (1 - \alpha)K^\alpha N^{1-\alpha} \hat{N}_t. \end{aligned}$$

应用稳态下的欧拉方程 (5), 可以解得

$$\begin{aligned} \hat{K}_{t+1} &= \frac{Y}{K} [\hat{z}_t + \alpha \hat{K}_t + (1 - \alpha) \hat{N}_t] - \frac{C}{K} \hat{C}_t + (1 - \delta) \hat{K}_t \\ &= \frac{1}{\beta} \hat{K}_t + \frac{Y}{K} [\hat{z}_t + (1 - \alpha) \hat{N}_t] - \frac{C}{K} \hat{C}_t. \end{aligned}$$



将  $\hat{N}_t = \frac{1}{\alpha+\zeta}\hat{z}_t + \frac{\alpha}{\alpha+\zeta}\hat{K}_t - \frac{1}{\alpha+\zeta}\hat{C}_t$  代入:

$$\hat{K}_{t+1} = \left( \frac{1}{\beta} + \frac{1-\alpha}{\alpha+\zeta} \alpha \frac{Y}{K} \right) \hat{K}_t + \frac{Y}{K} \left( \frac{1+\zeta}{\zeta+\alpha} \right) \hat{z}_t - \left( \frac{C}{K} + \frac{1-\alpha}{\alpha+\zeta} \frac{Y}{K} \right) \hat{C}_t. \quad (6)$$

对欧拉方程 (1) 在稳态取全微分

$$\begin{aligned} -\frac{dC_t}{C^2} = & -E_t \left\{ \frac{\beta dC_{t+1}}{C^2} [\alpha K^{\alpha-1} N^{1-\alpha} + 1 - \delta] \right\} \\ & + E_t \left\{ \frac{\beta}{C} [\alpha K^{\alpha-1} N^{1-\alpha} dz_{t+1} + \alpha(\alpha-1) K^{\alpha-2} N^{1-\alpha} dK_{t+1}] \right\} \\ & + E_t \left\{ \frac{\beta}{C} \alpha(1-\alpha) K^{\alpha-1} N^{-\alpha} dN_{t+1} \right\}. \end{aligned}$$

注意到  $dC_t = C\hat{C}_t$ ,  $dz_t = \hat{z}_{t+1}$ ,  $dK_{t+1} = K\hat{K}_{t+1}$ ,  $dN_{t+1} = N\hat{N}_{t+1}$ , 并且  $Y = K^\alpha N^{1-\alpha}$ , 进一步有

$$-\hat{C}_t = -\mathbf{E}_t [\hat{C}_{t+1}] + \beta\alpha \frac{Y}{K} \mathbf{E}_t [\hat{z}_{t+1} + (\alpha - 1)\hat{K}_{t+1} + (1 - \alpha)\hat{N}_{t+1}]$$

并将  $\hat{N}_t = \frac{1}{\alpha+\zeta}\hat{z}_t + \frac{\alpha}{\alpha+\zeta}\hat{K}_t - \frac{1}{\alpha+\zeta}\hat{C}_t$  代入:

$$\begin{aligned} -\hat{C}_t = & - \left[ 1 + (1 - \alpha)\beta\alpha \frac{Y}{K} \frac{1}{\alpha + \zeta} \right] \mathbf{E}_t [\hat{C}_{t+1}] + \beta\alpha \frac{Y}{K} \frac{1 + \zeta}{\alpha + \zeta} \mathbf{E}_t [\hat{z}_{t+1}] \\ & - \beta\alpha(1 - \alpha) \frac{Y}{K} \frac{\zeta}{\alpha + \zeta} \mathbf{E}_t [\hat{K}_{t+1}]. \end{aligned}$$

(7)

在劳动力市场,由欧拉方程 (2) 和实际劳动工资 (4) 可知劳动力市场的供给方程为

$$\frac{\chi C_t}{1 - N_t} = w_t. \quad (8)$$

以及对数线性化后的劳动力市场供给方程

$$\frac{N}{1 - N} \hat{N}_t = -\hat{C}_t + \hat{w}_t. \quad (9)$$

同时对 (4) 作对数线性化可得劳动力市场的需求方程

$$\hat{w}_t = \hat{z}_t + \alpha \hat{K}_t - \alpha \hat{N}_t. \quad (10)$$

对  $Y_t = z_t K_t^\alpha N_t^{1-\alpha}$  做对数线性化有

$$\hat{Y}_t = \alpha \hat{K}_t + (1 - \alpha) \hat{N}_t + \hat{z}_t. \quad (11)$$

对  $R_{kt} = \alpha z_t K_t^{\alpha-1} N_t^{1-\alpha}$  做对数线性化有

$$\hat{R}_{kt} = \hat{Y}_t - \hat{K}_t. \quad (12)$$

综合 (6),(7),(9),(10),(11),(12):

$$\hat{K}_{t+1} = \left( \frac{1}{\beta} + \frac{1-\alpha}{\alpha+\zeta} \alpha \frac{Y}{K} \right) \hat{K}_t + \frac{Y}{K} \left( \frac{1+\zeta}{\zeta+\alpha} \right) \hat{z}_t - \left( \frac{C}{K} + \frac{1-\alpha}{\alpha+\zeta} \frac{Y}{K} \right) \hat{C}_t$$

$$-\hat{C}_t = - \left[ 1 + (1-\alpha)\beta\alpha \frac{Y}{K} \frac{1}{\alpha+\zeta} \right] E_t [\hat{C}_{t+1}] + \beta\alpha \frac{Y}{K} \frac{1+\zeta}{\alpha+\zeta} E_t [\hat{z}_{t+1}]$$

$$- \beta\alpha(1-\alpha) \frac{Y}{K} \frac{\zeta}{\alpha+\zeta} E_t [\hat{K}_{t+1}]$$

$$\frac{N}{1-N} \hat{N}_t = -\hat{C}_t + \hat{w}_t.$$

$$\hat{w}_t = \hat{z}_t + \alpha \hat{K}_t - \alpha \hat{N}_t.$$

$$\hat{Y}_t = \alpha \hat{K}_t + (1-\alpha) \hat{N}_t + \hat{z}_t.$$

$$\hat{R}_{kt} = \hat{Y}_t - \hat{K}_t$$

$$\ln z_t = \rho \ln z_{t-1} + \sigma \varepsilon_t$$

# 贝叶斯计算的应用：Real Business Cycle 模型的估计

- 上述是状态空间模型 (state space model) 的方程组, 数据是  $\hat{Y}_t$ , 参数是  $\theta = (\alpha, \beta, \delta, \chi, \rho, \sigma)$ ,  $\{\hat{K}_t, \hat{C}_t, \hat{N}_t, \hat{z}_t\}$  是隐变量 (latent variable)
- 对于  $\theta$  选择合适的先验:

参数	先验分布	先验均值	先验标准差
$\alpha$	Beta	0.35	0.02
$\beta$	Beta	0.99	0.002
$\delta$	Beta	0.025	0.003
$\chi$	Gamma	1.65	0.02
$\rho$	Beta	0.9	0.05
$\sigma^2$	Inv-Gamma	0.01	$\infty$

- MCMC 获得  $\theta$  的后验分布。

