

# 马尔科夫链蒙特卡洛模拟与 Stata 应用

王群勇 (南开大学数量经济研究所, QunyongWang@outlook.com)

---

## Contents

### 蒙特卡洛模拟

#### 马尔科夫链蒙特卡洛模拟

- 马尔科夫链
- MCMC (MH 抽样)
- 模拟结果的质量诊断与统计

#### Gibbs 抽样

#### 贝叶斯计量分析与预测

## 蒙特卡洛模拟

计量经济学中很多模型的估计存在积分问题。比如随机效应面板模型，

$$y_{it} = x_{it}\beta + c_i + u_{it}, u_{it} \sim N(0, \sigma^2)$$

$y_i = (y_{i1}, \dots, y_{iT_i})$  的似然函数为

$$f(y_i|x_{it}, c_i) = \prod_{t=1}^{T_i} f(y_{it}|x_{it}, c_i)$$

$$f(y_i|x_{it}) = \int f(y_i|x_{it}, c_i) g(c_i) dc_i = E(f(y_i|x_{it}, c_i)) \leftarrow S^{-1} \sum_{s=1}^S f^{(s)}(y_i|x_{it}, c_i).$$

## 蒙特卡洛模拟

在所有随机效应面板模型中都存在相同的问题。比如随机效应 Probit 模型，

$$P(y_{it}|x_i, c_i) = \Phi(x_{it}\beta + c_i)^{y_{it}} (1 - \Phi(x_{it}\beta + c_i))^{1-y_{it}}$$

$y_i = (y_{i1}, \dots, y_{iT_i})$  的似然函数为

$$f(y_i|x_{it}, c_i) = \prod_{t=1}^{T_i} P(y_{it}|x_{it}, c_i)$$

$$f(y_i|x_{it}) = \int f(y_i|x_{it}, c_i) g(c_i) dc_i = E(f(y_i|x_{it}, c_i)) \leftarrow S^{-1} \sum_{s=1}^S f^{(s)}(y_i|x_{it}, c_i).$$

## 蒙特卡洛积分

蒙特卡洛积分：设  $x \sim g(x)$ , 求  $E(h(x)) = \int_{-\infty}^{\infty} h(x)g(x)dx$ .

根据大数定律,  $(x_1, x_2, \dots, x_n), \bar{x} \rightarrow E(x)$ .

从分布  $g(x)$  抽取随机数  $(x_1, x_2, \dots, x_S)$ ,

$$\bar{h}(x) = S^{-1} \sum_{i=1}^S h(x_i) \rightarrow E(h(x)).$$

例:  $\int_0^1 [\cos(50x) + \sin(20x)]^2 dx$ .

令  $x \sim Uniform(0,1)$

$$\int_0^1 [\cos(50x) + \sin(20x)]^2 dx = E([\cos(50x) + \sin(20x)]^2).$$

## 蒙特卡洛积分

```
. set obs 10000
Number of observations (_N) was 114, now 10,000.

. qui gen x = .

. gen n=_n
. mata
----- mata (type end to exit) -----
: n = 10000
```

```

: u = runiform(n,1)

: rmean= runningsum((cos(50*u) + sin(20*u))^2):/range(1,n,1)

: st_store(., "x", rmean)

: end

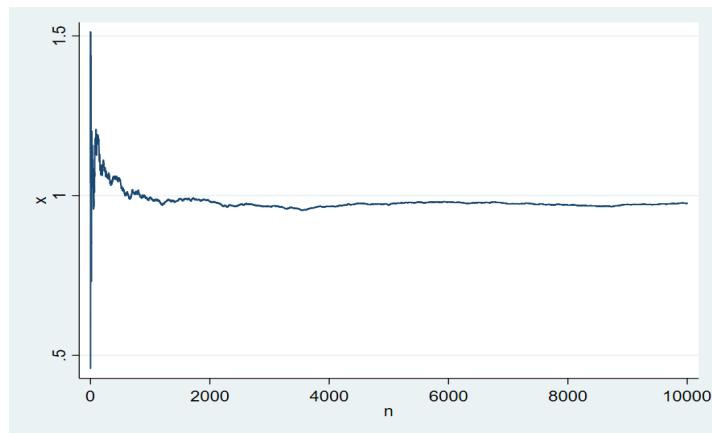

---




---


: line x n

```



## 参数估计量的模拟标准差

模型:  $\ln(y_t) = \rho \ln(y_{t-1}) + \ln(x_t)\beta + u_t$

长期弹性:  $\eta = \beta/(1 - \rho) \rightarrow \hat{\beta}/(1 - \hat{\rho})$ .

如何检验长期弹性的显著性或者置信区间:

- Delta 方法
- 抽取( $\beta, \rho$ )的 $S$ 个随机数, 直接计算 $\eta_s (s = 1, \dots, S)$ 。

## 传统的模拟方法

- 逆概率转换
- 合成法
- 接受拒绝法

- 重要性抽样法
- 

## Contents

蒙特卡洛模拟

马尔科夫链蒙特卡洛模拟

- 马尔科夫链
- MCMC (MH 抽样)
- 模拟结果的质量诊断与统计

Gibbs 抽样

贝叶斯计量分析与预测

## MCMC 与贝叶斯分析

贝叶斯定理:

$$P(A|B) = \frac{P(AB)}{P(B)} = \frac{P(B|A)P(A)}{P(A)P(B|A) + P(\bar{A})P(B|\bar{A})}$$

对于计量模型，数据为 $y$ ，参数为 $\theta$ 。贝叶斯定理表示为

$$\pi(\theta|y) = \frac{f(y|\theta)\pi(\theta)}{f(y)} \propto f(y|\theta)\pi(\theta).$$

即，后验分布  $\propto$  似然函数  $\times$  先验分布。 $f(y|\theta)\pi(\theta)$  叫做贝叶斯核(kernel)。其中， $f(y|\theta)$  为似然函数(概率密度函数)， $\pi(\theta)$  为先验分布， $\pi(\theta|y)$  为后验分布。

## 马尔科夫链

传统方法的局限：变量的分布必须具有明确的表达式。

随机过程 $X_t$ 取不同数值 $s = (1, 2, \dots, S)$ ，转移概率为

$$p_{ij} = P(X_{t+1} = j | X_t = i), i, j \in S.$$

比如，

$$P = \begin{bmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{bmatrix} = \begin{bmatrix} 1 - \alpha & \alpha \\ \beta & 1 - \beta \end{bmatrix}.$$

马尔可夫特征：随机变量的 $t$ 期状态只取决于 $t - 1$ 期状态。即下一步去哪里只取决于变量当前所在的位置，而不取决于是怎么到达当前位置的。

马尔科夫链：满足马尔科夫特征的随机过程。

## 马尔科夫链

如果  $\pi_t = (\pi_1, \dots, \pi_s)$ , 那么  $\pi_{t+1} = \pi_t P$ .

$$[\pi_{1,t+1} \quad \pi_{2,t+1}] = [\pi_{1t} \quad \pi_{2t}] \begin{bmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{bmatrix}$$

$$\pi_{t+n} = \pi_{t+n-1} P = \pi_{t+n-2} P^2 = \pi_t P^n.$$

平稳分布：如果分布  $\pi_t$  不再变化，即  $\pi = \pi P$ ,  $\pi$  称为平稳分布。

$\pi(I - P) = 0$ , 所以  $\pi$  为  $P$  矩阵特征值 1 对应的特征向量。

例：转移矩阵为

$$P = \begin{bmatrix} 0.75 & 0.25 \\ 0.125 & 0.875 \end{bmatrix}$$

可以求出其对应的平稳分布为  $(1/3, 2/3)$ .

## 马尔科夫链

例，从状态  $p = (0.1, 0.9)$  开始，经过 50 次转移，那么分布收敛到  $(1/3, 2/3)$ 。

```
. mata:  
----- mata (type end to exit) -----  
: K=(0.75,0.25 \ 0.125, 0.875)  
: p=(0.1, 0.9)  
: for (i=1; i<=50; i++) {  
> p = p*K  
> }  
: p  
1 2  
1 .3333333333 .6666666667
```

```
: p*K  
      1          2  
1  .3333333333  .6666666667
```

```
: end
```

---

## 马尔科夫链

从状态 $p = (0.6, 0.4)$ 开始:

```
. mata:  
----- mata (type end to exit) -----  
: K=(0.75,0.25 \ 0.125, 0.875)  
: p=(0.6, 0.4)  
: for (i=1; i<=50; i++) {  
>   p = p*K  
> }  
  
: p  
      1          2  
1  .3333333333  .6666666667  
  
: p*K  
      1          2  
1  .3333333333  .6666666667  
  
: end
```

---

## 马尔科夫链

对于一个转移矩阵，平稳分布可能不是唯一的。比如

$$P = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

可能存在无穷多的平稳分布。比如，转移矩阵为

$$\begin{bmatrix} 1/3 & 2/3 & 0 \\ 1/3 & 2/3 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

## 马尔科夫链

令  $P^{(n)} = \pi_t P^n$ , 如果  $P_{ij}^{(n)} > 0$ , 称  $j$  从  $i$  可达 (accessible)。

如果  $P_{ij}^{(n)} > 0$ ,  $P_{ji}^{(n)} > 0$ , 称  $i$  与  $j$  互通 (communicate)。一组互通的状态构成互通类 (communicate class)。

只包含一个互通类的马尔科夫链称为不可约的 (irreducible)。

**定理：**不可约的马尔科夫链具有唯一的平稳分布。

**含义：**对于目标分布，如果能找到其对应的马尔科夫链，那么总可以到达该分布。

---

## Contents

蒙特卡洛模拟

马尔科夫链蒙特卡洛模拟

- 马尔科夫链
- **MCMC (MH 抽样)**
- 模拟结果的质量诊断与统计

Gibbs 抽样

贝叶斯计量分析与预测

## MH 抽样

如何找到马尔科夫链？MCMC: Gibbs 抽样 (Geman and Geman, 1984), Metropolis-Hastings 抽样 (Metropolis et al., 1953; Hastings, 1970)

数值例子： $y = \sum y_i \sim binomial(10, \theta)$ , prior:  $\theta \sim Beta(1,1)$

设初始值  $\theta_1 = 0.517$ , 令  $\theta_{new} = 0.380$ ?

$$\rho = \frac{\text{posterior}(\theta_{new})}{\text{posterior}_{\theta_1}} = \frac{\text{Beta}(1,1,0.380) \times \text{Binomial}(10,4,0.380)}{\text{Beta}(1,1,0.517) \times \text{Binomial}(10,4,0.517)} = 1.307$$

$\theta_2 = 0.380$ , 令  $\theta_{new} = 0.286$ ?

$$\rho = \frac{\text{posterior}(\theta_{new})}{\text{posterior}_{\theta_2}} = \frac{\text{Beta}(1,1,0.286) \times \text{Binomial}(10,4,0.286)}{\text{Beta}(1,1,0.380) \times \text{Binomial}(10,4,0.380)} = 0.747$$

$\theta_3$  以 0.747 的概率取 0.286, 以 0.253 的概率取 0.380.

.....

? 如何生成  $\theta_{new}$ : 工具分布(proposal distribution).

## MCMC

MH 抽样: 设后验分布为  $f(\theta)$  ( $\theta$  代表模型的参数)

(1) 给定  $\theta_t$ , 定义工具分布  $q(y|\theta_t)$  (proposed distribution), 从  $q(y|\theta_t)$  抽取随机数  $\theta_{new}$ 。  
其中, 工具分布: (a)容易抽样; (b)定义域覆盖后验分布的定义域。

(2) 定义接受概率(acceptance probability):  $\rho(\theta_t, \theta_{new}) = \min \left[ \frac{f(\theta_{new}) q(\theta_t|\theta_{new})}{f(\theta_t) q(\theta_{new}|\theta_t)}, 1 \right]$ ,

$$\theta_{t+1} = \begin{cases} \theta_{new} & \rho(\theta_t, \theta_{new}) \\ \theta_t & 1 - \rho(\theta_t, \theta_{new}) \end{cases}$$

对称情形:  $q(\theta_t|\theta_{new}) = q(\theta_{new}|\theta_t)$ ,  $\rho(\theta_t, \theta_{new}) = \min \left[ \frac{f(\theta_{new})}{f(\theta_t)}, 1 \right]$ ,

独立情形:  $q(\theta_t|\theta_{new}) = q(\theta_t)$ ,  $q(\theta_{new}|\theta_t) = q(\theta_{new})$ ,  $\rho(\theta_t, \theta_{new}) = \min \left[ \frac{f(\theta_{new})}{f(\theta_t)} \frac{q(\theta_t)}{q(\theta_{new})}, 1 \right]$ 。

1. 如果  $q(\theta_t) = q(\theta_{new})$ , 那么  $\rho = \min[f(\theta_{new})/f(\theta_t), 1]$ .
2. 计算接受概率时, 分布中只有核起作用, 其它常数都被略掉。

## 独立 MH 抽样

1. 与 Accept-Reject 模拟抽样不同, MH 算法中每次迭代都有一个取值, 或者新的实验值, 或者是上一期的模拟值。
2. MH 模拟样本存在比较高的自相关, 自相关滞后阶数可能长达几十, 导致有效样本下降。
3. 有效的 MH 抽样需要将接受率控制在一个良好的范围内。

## 独立 MH 抽样

抽样效率：接受率。接受率太低意味着很多无效的抽样，导致模拟样本存在过高的自相关。但接受率也不是越高越好，过高的接受率可能意味着每次的变化太小，MH 抽样可能陷入一个局部的空间，而无法覆盖完整的定义域。合理的接受率在[0.15, 0.50]之间。

? 如何提高抽样效率? (a) 随机游走 MH 抽样; (b) 适应性 MH 抽样; (c) 分块抽样; (d) Gibbs 抽样; .....

MH 算法弹性很大，允许很多不同的算法。不同算法的效率是不一样的。

## 适应性随机游走 MH 抽样

适应性 MH 抽样是指每隔一定的区间调整 $\rho_t$ 和 $\Sigma_t$ ，以实现最优的接受率(TAR)。

$$\theta_{new} = \theta_{t-1} + e_t, e_t \sim N(0, \rho_t^2 \Sigma_t)$$

根据 Gelman, Gilks, and Roberts (1997)，单个参数的最优接受率为 0.44，多个参数的最优接受率为 0.234。 $(\rho_k, \Sigma_k)$ 的更新方程为

$$\begin{aligned}\rho_k &= \rho_{k-1} \exp[\beta_k(\Phi^{-1}(AR_k/2) - \Phi^{-1}(TAR/2))]. \\ \Sigma_k &= (1 - \beta_k)\Sigma_{k-1} + \beta_k \hat{\Sigma}_k.\end{aligned}$$

其中， $AR_k = (1 - \alpha)AR_{k-1} + \alpha \widehat{AR}_k$ .

根据 $AR_k$ 的公式，如果当前的接受率超过最优水平， $\rho_k$ 会提高，即工具密度的方差会增加，这会降低接受率。根据 Gelman, Gilks, and Roberts (1997), Roberts and Rosenthal (2001), and Andrieu and Thoms (2008)，初始值\$0 设定为 $2.38/\sqrt{d}$ ，其中， $d$ 表示参数的个数。 $\widehat{AR}_k$ 表示第 k 段的接受率， $\hat{\Sigma}_k$ 表示第 k 段中模拟数值的协方差。 $\alpha \in (0,1)$ 决定了 AR 的平滑水平， $\beta_k = \beta_0/k^\gamma$ ， $\beta_0 \in (0,1)$ ， $\gamma \in [0,1]$ 表示降低适应性调整的水平。可以参考的经验设定值， $\alpha = 0.75, \beta_0 = 0.8, \gamma = 0$ 。

可以设定适应性调整的区间长度、适应性调整的最小或最大次数、停止规则。比如，`alen=100`; 最小调整次数为 5，最大调整次数为 `max(25, burnin/alen)`; 当接受率 AR 与 TAR 接近时则停止调整，等等。

为了防止方差矩阵的退化，Roberts and Rosenthal (2009)建议用固定的方差矩阵，

$$\Sigma_k = (1 - \beta_k)\Sigma_{k-1} + \beta_k \Sigma_{fixed}.$$

## Stata: bayesmh

bayesmh 可以用于单方程线性模型、单方程非线性模型、多方程线性模型、多方程非线性模型、多水平模型、概率分布等。可以自己设定似然函数或后验分布。

贝叶斯预测(bayespredict)只能用于 bayesmh，而不能用于 bayes。

bayesmh *depvar* [*indepvars*] [*if*] [*in*] [*weight*], likelihood(*modelspec*) prior(*priorspec*)  
llevaluator(*log-likelihood*) evaluator(*log-postdist*) [*options*]

三种用法：

- **likelihood()** + **prior()**: 内置似然函数 + 内置先验分布
- **llevaluator()** + **prior()**: 自定义的对数似然函数 + 内置先验分布
- **evaluator()**: 自定义的对数后验分布

## Stata: bayesmh

似然函数即概率密度函数，不同分布涉及到的参数也不同。比如，正态分布有均值和方差两个参数；泊松分布只有一个参数，既为均值也是方差。

bayesmh 中，分布的均值参数通过模型来设定。分布的形式和其它参数则通过 likelihood() 来设定。比如，

- **bayesmh y x1 x2, likelihood(normal({var}))**, 表示  $y \sim N(b_0 + b_1x_1 + b_2x_2, var)$
- **bayesmh y x1 x2, likelihood(poisson)**, 表示  $y \sim Poisson(\exp(b_0 + b_1x_1 + b_2x_2))$
- **bayesmh y x1 x2, likelihood(probit)**, 表示  $y \sim Bernoulli(\Phi(b_0 + b_1x_1 + b_2x_2))$

## Stata: bayesmh

```
. use bintrial, clear  
. bayesmh y, likelihood(dbernoulli({p})) prior({p},beta(1,1))
```

Burn-in ...  
Simulation ...

Model summary

---

Likelihood:  
y ~ bernoulli({p})

Prior:  
 $\{p\} \sim \text{beta}(1,1)$

---

Bayesian Bernoulli model  
Random-walk Metropolis-Hastings sampling

MCMC iterations =	12,500
Burn-in =	2,500
MCMC sample size =	10,000
Number of obs =	10
Acceptance rate =	.4517
Efficiency =	.2739

Log marginal-likelihood = -7.8073834

	Mean	Std. dev.	MCSE	Median	Equal-tailed [95% cred. interval]	
p	.4235852	.1358498	.002596	.4210698	.1723984	.6930029

---

## Contents

蒙特卡洛模拟

马尔科夫链蒙特卡洛模拟

- 马尔科夫链
- MCMC (MH 抽样)
- 模拟结果的质量诊断与统计

Gibbs 抽样

贝叶斯计量分析与预测

## MCMC 诊断

接受率(Acceptance Rate, AR): 试验值被接受的概率。Roberts and rosenthal (2001)认为，有效抽样的接受率在 0.15-0.5 之间。

收敛性(是否达到平稳分布)

- 跟踪图 (trace plot) : 围绕常数均值波动

- 核密度图 (kernel density)：模拟样本分为前后两段，比较其分布。
- 自相关
- Gelman-Rubin (shrink factor)统计量：多条马尔科夫链进行抽样，那么链之间的平均差异与链内的平均差异应该进行相等。二者的比例称作收缩因子（shrink factor），作为经验规则，收缩因子应低于 1.1。

有效性 (Efficiency) 是衡量自相关的一个指标。大于 0.1，视作良好。低于 0.01，严重关注。

## MCMC 诊断

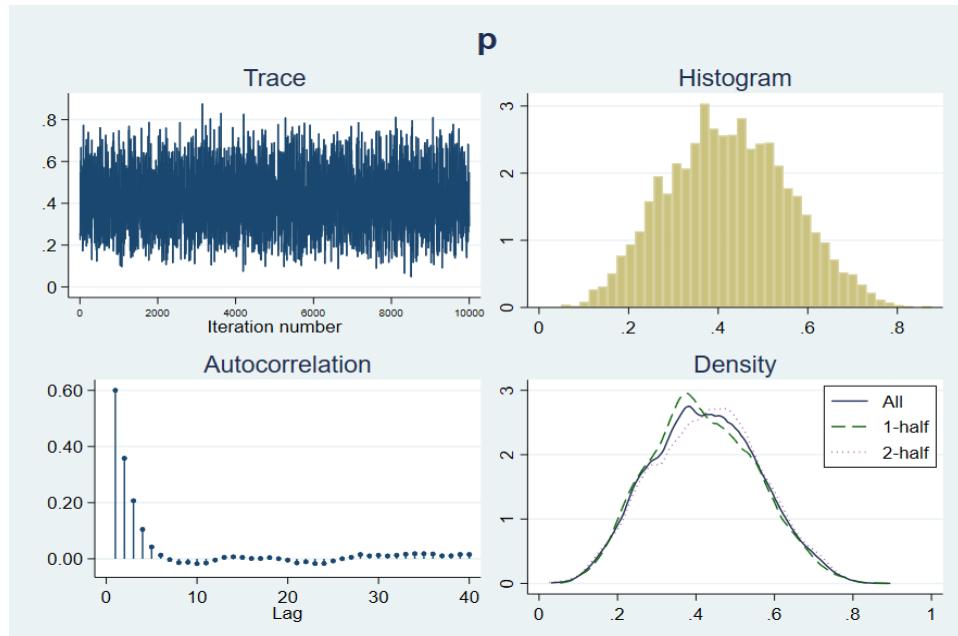
`bayesgraph type which`

其中，`type` 包括:`diag, trace, histogram, kdensity, ac, cusum, matrix`.

`which` 包括：`_all, {[eqname:]param}`

## MCMC 诊断

. `bayesgraph diag {p}`



## MC 抽样结果统计

设 MCMC 模拟得到样本量为  $T$ , 样本均值和标准差为

$$\bar{\theta} = T^{-1} \sum_{t=1}^T \theta_t; s^2 = (T-1)^{-1} \sum_{t=1}^T (\theta_t - \bar{\theta})^2.$$

如果 MCMC 多条链, 那么(Gelman et al. 2014)

$$\begin{aligned}\bar{\theta} &= \frac{1}{MT} \sum_{j=1}^M \sum_{t=1}^T \theta_{jt}. \\ s^2 &= \frac{T-1}{T} W + \frac{1}{T} B; B = \frac{T}{M-1} \sum_{j=1}^M (\bar{\theta}_j - \bar{\theta})^2; W = \frac{1}{M} \sum_{j=1}^M s_j^2.\end{aligned}$$

## MC 抽样结果统计

由于  $\theta_t$  存在自相关, 后验均值的标准差 (也叫做蒙特卡洛标准误差, MCSE) 不能通过  $s/\sqrt{T}$  来估计。两种解决方法: 有效样本水平(ESS)和块均值 (batch mean)。

$$\begin{aligned}ESS &= \frac{T}{1 + 2 \sum_{k=1}^K \rho_k}; Efficiency = ESS/T; Correlation time = T/ESS. \\ \rho_k &= \frac{\gamma_k}{\gamma_0}; \quad \gamma_k = \frac{1}{T} \sum_{t=1}^{T-k} (\theta_t - \bar{\theta})(\theta_{t+k} - \bar{\theta}); \gamma_0 = \frac{1}{T} \sum_{t=1}^{T-k} (\theta_t - \bar{\theta})^2.\end{aligned}$$

其中,  $\rho_k$  为  $k$  阶自相关系数;  $\gamma_k$  为自协方差系数。

最高阶数  $K$  可以自行设定 (`corrlag()`, Stata 默认值为  $\min(500, T/2)$ )。或者根据自相关系数高于某个阈值 (`corrto1()`, 默认值为 0.01) 来判断。

$$MCSE(\bar{\theta}) = \frac{s}{\sqrt{ESS}}; \text{ or } MCSE(\bar{\theta}) = \frac{s}{\sqrt{\sum_{j=1}^M ESS_j}}$$

## MC 抽样结果统计

有效样本:

```

. use bintrial, clear

. qui bayesmh y, likelihood(dbernoulli({p})) prior({p},beta(1,1))

. bayesstats ess

```

Efficiency summaries MCMC sample size = 10,000

	ESS	Corr. time	Efficiency
p	2298.71	4.35	0.2299

## MC 抽样结果统计

```
. bayesstats summary _all, corrlag(100)
```

Posterior summary statistics MCMC sample size = 10,000

	Mean	Std. dev.	MCSE	Median	Equal-tailed [95% cred. interval]
p	.4189065	.1381554	.002882	.4111325	.168179 .6951997

## MC 抽样结果统计

块均值 (Jones et al. 2006) : 将( $\theta_1, \dots, \theta_T$ )分为 m 块, 每块的均值为  $\bar{\theta}_j$ 。块均值 (batch mean) 为

$$\bar{\theta} = \frac{1}{m} \sum_{j=1}^m \bar{\theta}_j.$$

$$s_{batch}^2 = \frac{1}{m-1} \sum_{j=1}^m (\bar{\theta}_j - \bar{\theta})^2.$$

$$MCSE_{batch}(\bar{\theta}) = s_{batch}/\sqrt{m}.$$

Flegal and Jones(2010)证明，最优的块长度为 $O(T^{1/3})$ 。

## MC 抽样结果统计

```
. bayesstats summary _all, batch(20)
```

```
Posterior summary statistics
```

MCMC sample size =	10,000
Batch size =	20

	Mean	Std. dev.	MCSE	Median	Equal-tailed [95% cred. interval]
p	.4189065	.1381554	.002633	.4111325	.168179 .6951997

Note: Mean and MCSE are estimated using batch means.

---

## Contents

蒙特卡洛模拟

马尔科夫链蒙特卡洛模拟

- 马尔科夫链
- MCMC (MH 抽样)
- 模拟结果的质量诊断与统计

## Gibbs 抽样

贝叶斯计量分析与预测

## 分块 MH 抽样

比如，线性回归模型：

$$y = x\beta + u, u \sim (0, \sigma^2), \sigma^2 \sim \text{Inv-Gamma}(a, b)$$

分块 MH 抽样是将变量分为若干子集。不同组的参数的先验分布是独立的，为不同组设计独立的不同的工具分布，每个子集的变量联合抽样。

## 分块 MH 抽样

将参数分为两组,  $(x, y)$ , 每组变量的工具密度为  $q_x(x|y), q_y(y|x)$ 。

设置初始值  $(x_0, y_0)$ :

- 抽取替代值  $x_{new} \sim q_x(x|y)$ , 接受概率为

$$\rho_x = \frac{f(x_{new}|y_0)}{f(x_0|y_0)} \times \frac{q_x(x_0|(x_{new}, y_0))}{q_x(x_{new}|(x_0, y_0))}$$

- 抽取替代值  $y_{new} \sim q_y(y|x)$ , 接受概率为

$$\rho_y = \frac{f(y_{new}|x_1)}{f(y_0|x_1)} \times \frac{q_y(y_0|(y_{new}, x_1))}{q_y(y_{new}|(y_0, x_1))}$$

## 分块 MH 抽样

在回归模型中, Stata 自动将回归系数和方差参数分组。

```
. use taylor, clear

. bayes, saving(mhtaylor, replace) : regress ffr L.ffr L.pi L.ygap

Burn-in ...
Simulation ...

file mhtaylor.dta saved.

Model summary


---


Likelihood:
  ffr ~ regress(xb_ffr,{sigma2})

Priors:
  {ffr:L.ffr L.pi L.ygap _cons} ~ normal(0,10000)          (1)
  {sigma2} ~ igamma(.01,.01)


---


(1) Parameters are elements of the linear form xb_ffr.
```

Bayesian linear regression	MCMC iterations =	12,500
Random-walk Metropolis-Hastings sampling	Burn-in =	2,500
	MCMC sample size =	10,000

```

Number of obs      =       113
Acceptance rate   =     .3335
Efficiency: min  =     .04356
                           avg =     .08301
                           max =     .1671
Log marginal-likelihood = -186.89491

```

		Mean	Std. dev.	MCSE	Median	Equal-tailed [95% cred. interval]
ffr						
ffr	L1.	.8064498	.0434149	.001676	.8048175	.7167563    .8942407
pi	L1.	.3976928	.087098	.00335	.3980353	.223583    .5684021
ygap	L1.	.2578887	.0759919	.003641	.258645	.107127    .4120811
_cons		-.0616117	.200531	.007595	-.0623522	-.4526737    .3494749
sigma2		.9037473	.1259337	.003081	.8893884	.6929364    1.179869

Note: Default priors are used **for model** parameters.

. est store mod1

注: 在用 `est store` 保存估计结果之前, `bayes` 必须用 `saving()` 保存模拟的结果。

## Gibbs 抽样

如果工具密度与条件分布完全相同, 即

$$q_m(t|x_1, \dots, x_M) = f(x_m = t|x_1, \dots, x_{m-1}, x_{m+1}, \dots, x_M)$$

那么接受概率为

$$\rho_m = \frac{f(x_{m,new}|x_1, \dots, x_{m-1}, x_{m+1}, \dots, x_M)}{f(x_{m,t}|x_1, \dots, x_{m-1}, x_{m+1}, \dots, x_M)} \times \frac{f(x_{m,t}|x_1, \dots, x_{m-1}, x_{m+1}, \dots, x_M)}{f(x_{m,new}|x_1, \dots, x_{m-1}, x_{m+1}, \dots, x_M)} = 1$$

称之为 Gibbs 抽样。Gibbs 抽样是对每个参数的条件分布进行抽样。

Gibbs 抽样的优势: 100%的接受率。

劣势: 需要得到条件分布的明确的解析式。因此, 只是在某些特殊情况下可以使用。

## Gibbs 抽样

将随机变量分为两组,  $(x_t, y_t)$ , 联合密度为  $f(x, y)$ 。

- 抽取  $x_0$
- $t = 1, 2, \dots$ , 抽取  $y_{t+1} \sim f(y|x_t), x_{t+1} \sim f(x|y_{t+1})$

例: 二元正态分布。

抽取  $x_0 = 0$ 。令  $t = 1, 2, \dots$ , 抽取

$$\begin{aligned} y_{t+1}|x_t &\sim N\left(\frac{\sigma_1}{\sigma_2}\rho x_t, (1-\rho^2)\sigma_1^2\right) \\ x_{t+1}|y_{t+1} &\sim N\left(\frac{\sigma_2}{\sigma_1}\rho y_{t+1}, (1-\rho^2)\sigma_2^2\right) \end{aligned}$$

可以直接扩展到随机变量分为多组的情况: Gibbs 依次从  $f(x_m|x_{-m})$  ( $m = 1, 2, \dots, M$ ) 进行抽样, 其中  $x_{-m}$  表示除了  $x_m$  之外所有其它变量。

## Gibbs 抽样: 线性回归

模型:  $y = x\beta + u$

似然函数:  $y_i \sim Normal(x_i\beta, \sigma^2)$

先验分布:

$$\begin{aligned} \beta &\sim \text{Multivariate-Normal}(\beta_0, V_0) \\ \sigma^2 &\sim \text{Inverse-Gamma}(\alpha_0/2, \delta_0/2) \end{aligned}$$

边际后验分布:

$$\begin{aligned} \beta|\sigma^2, y &\sim \text{Multivariate-Normal}(\beta_1, V_1) \\ V_1 &= [\sigma^{-2}X'X + V_0^{-1}]^{-1}, \beta_1 = V_1[\sigma^{-2}X'y + V_0^{-1}\beta_0] \\ \sigma^2|\beta, y &\sim \text{Inverse-Gamma}((\alpha_0 + n)/2, [\delta_0 + (y - x\beta)'(y - x\beta)]/2). \end{aligned}$$

## Gibbs 抽样: 线性回归

1. 选择  $\sigma^{2(0)}$  的初始值.
2. 在第  $t$  次迭代,

$$\begin{aligned}\beta^{(t)} | \sigma^2, y &\sim \text{MNormal}(\beta_1, V_1) \\ \sigma^2 | \beta, y &\sim \text{IG}\left((\alpha_0 + n)/2, [\delta_0 + (y - x\beta^{(t)})'(y - x\beta^{(t)})]/2\right).\end{aligned}$$

## Gibbs 抽样：例

```
. use taylor, clear

. bayes, gibbs : regress ffr L.ffr L.pi L.ygap

Burn-in ...
Simulation ...

Model summary

```

---

Likelihood:  
 $ffr \sim \text{normal}(xb\_ffr, \{\sigma^2\})$

---

Priors:  
 $\{ffr: L.ffr L.pi L.ygap \_cons\} \sim \text{normal}(0, 10000)$  (1)  
 $\{\sigma^2\} \sim \text{igamma}(.01, .01)$

---

(1) Parameters are elements of the linear form  $xb\_ffr$ .

Bayesian linear regression Gibbs sampling	MCMC iterations = 12,500 Burn-in = 2,500 MCMC sample size = 10,000 Number of obs = 113 Acceptance rate = 1 Efficiency: min = .9539 avg = .9849 max = 1
Log marginal-likelihood = -186.84401	

---

		Mean	Std. dev.	MCSE	Median	Equal-tailed	
						[95% cred. interval]	
ffr	ffr						
	L1.	.8072651	.0443575	.000444	.8071702	.7203961	.8947774
	pi						
	L1.	.3984596	.0892444	.000892	.398595	.2208014	.5715274
	ygap						
	L1.	.2602214	.0756185	.000756	.2597978	.1120771	.4083866
	_cons	-.0706846	.195486	.001984	-.0697387	-.4545969	.3162705

sigma2	.9039901	.1246499	.001276	.8923206	.6947758	1.184623
--------	----------	----------	---------	----------	----------	----------

Note: Default priors are used **for model** parameters.

## Gibbs 抽样

半共轭先验：条件后验分布与先验分布服从同一个分布族。共轭先验是指所有参数的后验分布与联合先验同属一个分布族。

线性回归： $y = x\beta + u, u \sim (0, \sigma^2)$ .  $\beta \sim \text{Multivariate-Normal}, \sigma^2 \sim \text{Inverse-Gamma}$ .

Probit 回归： $P(y = 1) = \Phi(x\beta)$ .  $\beta \sim \text{Multivariate-Normal}$ .

## 提高 MH 抽样有效性

是否有 Gibbs 算法

提高模拟样本量(`mcmcsize()`)；燃烧样本量(`burnin()`)；间隔取值(`thinning()`)

修改先验分布(`prior()`)：为受限分布的参数设定合理的先验，比如参数取离散值、取正数、取负数、取特定区间（比如 0-1）等。

设定模拟的初始值

观察参数的相关性，进行分块抽样(`block()`)

## Stata

`bayesopts note`  
`nchain(#)` 链的个数，默认值为 `nchain(1)`  
`mcmcsize(#)` 模拟样本量，默认值为 `mcmcsize(10000)`  
`burnin(#)` 默认值为 `burnin(2500)`  
`thinning(#)` 间隔数，默认值为 `thining(1)`  
`rseed(#)`

## Contents

蒙特卡洛模拟

马尔科夫链蒙特卡洛模拟

- 马尔科夫链
- MCMC (MH 抽样)
- 模拟结果的质量诊断与统计

Gibbs 抽样

贝叶斯计量分析与预测

## Stata: bayes

bayes [, bayesopts] : estimation\_command [, estopts]

bayesopts note

normalprior(#) 回归系数的正态先验分布的标准差, 默认值为 100 (方差为 10,000)

igammapior(# #) 回归模型的方差的先验分布: inverse-gamma 分布(shape, scale), 默认值为 igammapior(0.01 0.01)

prior(priorspec) 自己设定先验分布

gibbs 只适用于 regress, mvreg 等模型

其中, priorspec 的形式为: {[eqname:]param[, matrix]}, priordist。比如,

```
prior({lwage:educ}, normal(0, 9)) prior({lwage:age}, uniform(-3,3))
```

```
mvec = (1,0,2)  
vmat = I(3)*100  
prior({lwage:}, mvnormal(3, mvec, vmat))
```

## Stata: bayes

Stata 对不同模型的不同类型的参数设置了不同的先验分布。

回归系数的先验分布默认为独立的正态分布  $N(0, \sigma_{prior}^2)$ , 其中  $\sigma_{prior}^2 = 10,000$ 。

- 在多数情况下， $N(0,10,000)$ 是无信息的（uninformative），但如果估计量的数值非常大（比如 2000），那么标准差 100 会仍然含有较强的信息（informative）。这时，需要自己通过 **normalprior()** 设定先验分布的方差。
- 一般情况下，可以通过更改变量的测量单位以得到大小适宜的估计量。

正值的参数（比如方差）默认先验分布为 Inverse-Gamma( $\alpha, \beta$ )。默认值为  $\alpha = 0.01, \beta = 0.01$ 。

## 贝叶斯计量模型

```
. use taylor, clear

. bayes, gibbs : regress ffr L.ffr L.pi L.ygap

Burn-in ...
Simulation ...

Model summary


---


Likelihood:
  ffr ~ normal(xb_ffr,{sigma2})

Priors:
  {ffr:L.ffr L.pi L.ygap _cons} ~ normal(0,10000)                               (1)
  {sigma2} ~ igamma(.01,.01)


---


(1) Parameters are elements of the linear form xb_ffr.

Bayesian linear regression
Gibbs sampling
  MCMC iterations = 12,500
  Burn-in = 2,500
  MCMC sample size = 10,000
  Number of obs = 113
  Acceptance rate = 1
  Efficiency: min = .9491
  avg = .9898
  max = 1
Log marginal-likelihood = -186.86974


---



|     | Mean     | Std. dev. | MCSE    | Median  | Equal-tailed [95% cred. interval] |
|-----|----------|-----------|---------|---------|-----------------------------------|
| ffr |          |           |         |         |                                   |
| ffr |          |           |         |         |                                   |
| L1. | .8061786 | .0438886  | .000439 | .806048 | .7197456 .8916158                 |
| pi  |          |           |         |         |                                   |


```

L1.	.4004203	.0878048	.000878	.3996643	.2285947	.5742032
ygap L1.	.261852	.0738843	.000739	.2616932	.1124488	.4088988
_cons	-.0689398	.1941942	.001922	-.0680123	-.4544787	.3127534
sigma2	.903169	.1246849	.00128	.8932442	.6902638	1.177074

Note: Default priors are used for model parameters.

## 贝叶斯预测

由于参数是随机的，MCMC 模拟得到  $T$  个值。因此，其对单个观测值存在  $T$  个预测值。样本量为  $N$  的样本，预测值为  $T \times N$  矩阵。

$$\begin{aligned}y_i &= x_i\beta + u_i, i = 1, 2, \dots, N \\ \beta &= (\beta^{(1)}, \beta^{(2)}, \dots, \beta^{(T)})\end{aligned}$$

即，对每个观测值的预测都对应一个变量。如果对所有观测值进行贝叶斯预测，那么会得到  $N$  个预测变量，每个预测变量有  $T$  个贝叶斯预测值。

由于预测的数据量较大，一般只对部分感兴趣的观测值或者观测的描述指标进行贝叶斯预测，比如均值、中位数、最小值、最大值、四分间距等。

也可以只利用  $T$  个模拟值的一部分进行贝叶斯预测。

## 贝叶斯预测: Stata

`bayespredict {_ysim#[numlist]}`

`numlist` 设定对哪些观测值进行预测。得到的预测结果：

- 因变量的  $N$  个预测变量: `_ysim1_1, _ysim1_2, ..., _ysim1_N`, 表示第 1 个方程中第 1、2、...、 $N$  个观测值的预测变量。
- 残差为: `_resid1_1, _resid1_2, ..., _ysim1_N`, 表示第 1 个方程中第 1、2、...、 $N$  个残差的预测变量。
- 均值为: `_mu1_1, _mu1_2, ..., _mu1_N`, 表示第 1 个方程中第 1、2、...、 $N$  个期望值的预测变量。

Stata 根据 `bayesmh` 中 `likelihood()` 或 `bayesmh` 所设定的模型自动计算期望值。比如，第  $i$  个观测的第  $t$  次模拟：

- 线性回归:  $\mu_i^{(t)} = x_i\beta^{(t)}$
  - Probit:  $\mu_i^{(t)} = \exp(x_i\beta^{(t)})$

`bayespredict` 只能用于 `bayesmh`, 而不能用于 `bayes`。

## 贝叶斯预测

```

. use taylor, clear

. qui bayesmh ffr l.(ffr pi ygap) in 1/-6, likelihood(normal({var})) prior({ff
r:}, normal(10)) prior({var}), igamma(0.01
> , 0.01) saving(taylormh, replace) rseed(123)

. bayespredict {_ysim} in 110/114, saving(taylor_pred, replace) rseed(16)

Computing predictions ...

file taylor_pred.dta saved.
file taylor_pred.ster saved.

. describe _ysim1_110 _ysim1_111 _ysim1_114 using taylor_pred

Variable      Storage   Display       Value
      name        type    format     label      Variable label
_____
_ysim1_110      double   %10.0g      Simulated ffr, obs #110
_ysim1_111      double   %10.0g      Simulated ffr, obs #111
_ysim1_114      double   %10.0g      Simulated ffr, obs #114

```

贝叶斯预测

模拟的后 5 个观测值的统计指标。

```
. bayesstats summary {_ysim[110/114]} using taylor_pred
```

## Posterior summary statistics

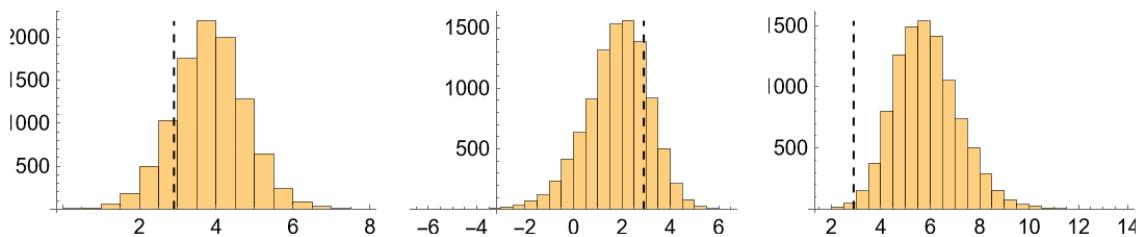
MCMC sample size = 10,000

	Mean	Std. dev.	MCSE	Median	[95% cred. interval]	Equal-tailed
_ysim1_110	5.447771	.9888649	.011341	5.450288	3.480159	7.397394
_ysim1_111	5.510331	.9842391	.009942	5.505292	3.574745	7.416676
_ysim1_112	5.352498	.9961558	.010243	5.353572	3.380797	7.32326
_ysim1_113	5.290157	.9758961	.009759	5.300427	3.386443	7.218715
_ysim1_114	5.181558	.9752148	.010116	5.192345	3.261653	7.076171

## 贝叶斯预测

贝叶斯预测也是检查模型设定的一种方法，通过比较预测值的统计量(比如，均值、最小值、最大值、分位数、偏度、峰度、对称性)分布与实际观测值的统计量进行比较检验(`bayestest_interval`)。

观测值	$y_{46}$	$y_{47}$	$y_{48}$	$y_{49}$	$y_{50}$	mean	min	max
observed	2.9	2.9	2.9	2.9	2.9	⇒	2.9	2.9
simulated	5.01724	1.68042	3.93164	5.10653	6.3661	4.42038	1.68042	6.3661
	3.21664	2.61576	6.89439	4.5356	-1.49672	3.15313	-1.49672	6.89439
	2.64348	5.82413	3.15353	0.339442	1.79671	2.75146	0.339442	5.82413
	8.97096	3.68248	4.03834	4.89328	5.27929	5.37287	3.68248	8.97096
	7.24218	4.91776	4.12351	4.69013	3.0464	4.804	3.0464	7.24218
	...	...	...	...	...	...	...	...



## 贝叶斯预测

```
. bayesstats ppvalues (mean:@mean({_ysim})) (min:@min({_ysim})) (max:@max({_ysim})) using taylor_pred
```

Posterior predictive summary MCMC sample size = 10,000

T	Mean	Std. dev.	E(T_obs)	P(T>=T_obs)
---	------	-----------	----------	-------------

mean	5.356463	.4496118	5.214667	.6276
min	4.211609	.6729031	5.073333	.0896
max	6.504275	.6754822	5.256667	.979

Note:  $P(T \geq T_{\text{obs}})$  close to 0 or 1 indicates lack of fit.

这些统计量的概率值越接近 0.5，表明模拟值与实际值越吻合。

贝叶斯诊断主要考察抽样的收敛性，而贝叶斯预测检查是考察模型设定的合理性。不合理的模型也往往容易影响到 MCMC 抽样的有效性。

谢谢！