

Lecture 9: Markov Chain Monte Carlo Methods

(二)

(马尔科夫蒙特卡罗方法)

张伟平

Monday 2nd November, 2009

Contents

1	Markov Chain Monte Carlo Methods	1
1.4	The Gibbs Sampler	1
1.4.1	The Slice Gibbs Sampler	12
1.5	Monitoring Convergence	21
1.5.1	Convergence diagnostics plots	21
1.5.2	Monte Carlo Error	22
1.5.3	The Gelman-Rubin Method	25
1.6	WinBUGS Introduction	33
1.6.1	Building Bayesian models in WinBUGS	33
1.6.2	Model specification in WinBUGS	36
1.6.3	Data and initial value specification	38
1.6.4	Compiling model and simulating values	46

Chapter 1

Markov Chain Monte Carlo Methods

1.4 The Gibbs Sampler

Gibbs 抽样是MH算法的一个特例, 其经常用于目标分布是多元分布的场合.
假设所有的一元条件分布 (每个分量对其他分量的条件分布)都是可以确定的,
Gibbs抽样使用这些一元条件分布进行抽样.

令 $X = (X_1, \dots, X_d)$ 为 R^d 中的随机变量, 定义 $d - 1$ 维的随机变量

$$X_{-j} = (X_1, \dots, X_{j-1}, X_{j+1}, \dots, X_d),$$

并记 $X_j | X_{-j}$ 的条件密度为 $f(X_j | X_{-j})$. 则 Gibbs 抽样是从这 d 个条件分布中产生候选点. 算法如下:

1. 在 $t = 0$ 时, 初始化 $X(0)$;

2. 对 $t = 1, 2, \dots, T$,

(a) 令 $x_1 = X_1(t - 1)$.

(b) 对每个分量 $j = 1, \dots, d$,

(i) 从 $f(X_j | x_{-j})$ 中产生候选点 $X_j^*(t)$.

(ii) 更新 $x_j = X_j^*(t)$.

(c) 令 $X(t) = (X_1^*(t), \dots, X_d^*(t))$ (每个候选点都被接受)

(d) 增加 t

注意在上述算法(b)步抽样中, 各个分量依次被更新:

$$x_1(t) \sim f(x_1 | x_2(t - 1), \dots, x_d(t - 1));$$

$$x_2(t) \sim f(x_2 | x_1(t), x_3(t - 1), \dots, x_d(t - 1))$$

⋮

$$x_d(t) \sim f(x_d | x_1(t), \dots, x_{d-1}(t)).$$

从一元分布 $f(x_j|x_1(t), x_2(t), \dots, x_{j-1}(t), x_{j+1}(t-1), \dots, x_d(t-1))$ 中抽样是比较容易的, 因为 $f(x_j|x_{-j}) \propto f(x)$, 其中除了变量 x_j 外, 其他变量都是常数.

例 1 (Gibbs 抽样: 二元分布) 使用Gibbs抽样产生二元正态分布 $N(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)$ 的随机数

在二元正态场合, $X_1|X_2$ 以及 $X_2|X_1$ 仍然服从正态分布, 且易知

$$E[X_1|X_2 = x_2] = \mu_1 + \rho \frac{\sigma_1}{\sigma_2} (x_2 - \mu_2),$$
$$Var[X_1|X_2 = x_2] = (1 - \rho^2)\sigma_1^2$$

类似可得 $X_2|X_1$ 的分布. 因此

$$f(x_1|x_2) \sim N(\mu_1 + \rho \frac{\sigma_1}{\sigma_2} (x_2 - \mu_2), (1 - \rho^2)\sigma_1^2)$$
$$f(x_2|x_1) \sim N(\mu_2 + \rho \frac{\sigma_2}{\sigma_1} (x_1 - \mu_1), (1 - \rho^2)\sigma_2^2)$$

因此, 使用Gibbs算法如下

1. 令 $(x_1, x_2) = X(t - 1)$;
2. 从 $f(x_1|x_2)$ 中产生候选点 $X_1^*(t)$.
3. 更新 $x_1 = X_1^*(t)$.
4. 从 $f(x_2|x_1)$ 中产生 $X_2^*(t)$.
5. 令 $X(t) = (X_1^*(t), X_2^*(t))$.

R 代码如下

↑Code

```
#initialize constants and parameters
N <- 5000                  #length of chain
burn<- 1000                 #burn-in length
X <- matrix(0, N, 2)        #the chain, a bivariate sample

rho <- -.75                  #correlation
mu1 <- 0
mu2 <- 2
sigma1 <- 1
sigma2 <- .5
s1 <- sqrt(1-rho^2)*sigma1
```

```

s2 <- sqrt(1-rho^2)*sigma2

##### generate the chain #####
X[, ] <- c(mu1, mu2)                      #initialize

for (i in 2:N) {
  x2 <- X[i-1, 2]
  m1 <- mu1 + rho * (x2 - mu2) * sigma1/sigma2
  X[i, 1] <- rnorm(1, m1, s1)
  x1 <- X[i, 1]
  m2 <- mu2 + rho * (x1 - mu1) * sigma2/sigma1
  X[i, 2] <- rnorm(1, m2, s2)
}

b <- burn + 1
x <- X[b:N, ]

```

[↓Code](#)

产生的链开始的1000个观测被丢弃掉, 剩下的观测存在 x 中, 对此样本 计算均值和协方差矩阵如下. 各参数的样本估计离真值很近, 散点图也显示出 二元正

态所具有的球面对称性和负相关性特征.

```
# compare sample statistics to parameters  
colMeans(x)  
cov(x)  
cor(x)  
  
plot(x, main="", cex=.5, xlab=bquote(X[1]),  
      ylab=bquote(X[2]), ylim=range(x[,2]))
```

↑Code

↓Code

例 2 (贝叶斯分析例子: 身体温度数据) 考虑 Mackowiak et al. (1992) 的数据, 该数据记录了 130 个人的身体温度(华氏), 性别和每分钟的心跳. 实验的目的是检验 Carl Wunderlich 的观点— 健康成年人的体温平均为 $37^{\circ}C (=98.6^{\circ}F)$.

记温度为 $y_i, i = 1, \dots, n$, 并假设正态模型

$$y_i \sim N(\mu, \sigma^2)$$

以及取先验分布为

$$\mu \sim N(\mu_0, \sigma_0^2), \quad \sigma^2 \sim IG(a_0, b_0)$$

则此时我们的目标分布为 μ, σ^2 的后验分布

$$f(\mu, \sigma^2 | y) \propto f(y|\mu, \sigma^2) \pi(\mu) \pi(\sigma^2)$$

为使用Gibbs抽样算法, 我们必须计算 $f(\mu|\sigma^2, y)$ 与 $f(\sigma^2|\mu, y)$. 经过计算我们得到

$$\mu|\sigma, y \sim N\left(\omega \bar{y} + (1 - \omega)\mu_0, \omega \frac{\sigma^2}{n}\right), \quad \omega = \frac{\sigma_0^2}{\sigma^2/n + \sigma_0^2}.$$

$$\sigma^2|\mu, y \sim IG\left(a_0 + \frac{n}{2}, b_0 + \frac{1}{2} \sum_{i=1}^n (y_i - \mu)^2\right).$$

使用此结果, Gibbs抽样算法如下:

对 $t = 1, \dots, T$,

1. 令 $\mu = \mu^{(t-1)}$, $\sigma = \sigma^{(t-1)}$.
2. 计算 $\omega = \frac{\sigma_0^2}{\sigma^2/n + \sigma_0^2}$, $m = \omega \bar{y} + (1 - \omega)\mu_0$ 和 $s^2 = \omega \frac{\sigma^2}{n}$.
3. 从 $N(m, s^2)$ 中产生 μ .
4. 令 $\mu^{(t)} = \mu$.
5. 计算 $a = a_0 + \frac{n}{2}$, $b = b_0 + \frac{1}{2} \sum_{i=1}^n (y_i - \mu)^2$.
6. 从 $G(a, b)$ 中产生 τ .
7. 令 $\sigma^2 = 1/\tau$ 以及 $\sigma^{(t)} = \sigma$.

从而R代码如下:

```
bodytemp<-read.table("bodytemp.txt",header=T)
y<-bodytemp$temp
bary<-mean(y); n<-length(y)
Iterations<-3500
mu0<-0; s0<-100; a0<-0.001; b0<-0.001
```

↑Code

```

theta <- matrix(nrow=Iterations, ncol=2)
cur.mu<-0; cur.tau<-2; cur.s<-sqrt(1/cur.tau)
for (t in 1:Iterations){
  w<- s0^2/( cur.s^2/n+ s0^2 )
  m <- w*bary + (1-w)*mu0
  s <- sqrt( w/n ) * cur.s
  cur.mu <- rnorm( 1, m, s )
  a <- a0 + 0.5*n
  b <- b0 + 0.5 * sum( (y-cur.mu)^2 )
  cur.tau <- rgamma( 1, a, b )
  cur.s <- sqrt(1/cur.tau)
  theta[t,]<-c( cur.mu, cur.s)
}
mcmc.output<-theta
apply(mcmc.output [-(1:1000),],2,mean)
#compare to true value: 98.25, 0.542
apply(mcmc.output [-(1:1000),],2,sd)
#compare to true value: 0.06456, 0.06826

```

[↓ Code](#)

对链的诊断图

↑Code

```
par( mfrow=c(3,2), xaxs='r', yaxs='r', bty='l' , cex=0.8)
iter<-1500
burnin<-500
index<-1:iter
index2<-(burnin+1):iter

plot(index, theta[index,1], type='l', ylab='Values of mu',
      xlab='Iterations', main='(a) Trace Plot of mu')
plot(index, theta[index,2], type='l', ylab='Values of sigma',
      xlab='Iterations', main='(b) Trace Plot of sigma')

ergtheta0<-erg.mean( theta[index,1] )
ergtheta02<-erg.mean( theta[index2,1] )
ylims0<-range( c(ergtheta0,ergtheta02) )

ergtheta1<-erg.mean( theta[index,2] )
ergtheta12<-erg.mean( theta[index2,2] )
ylims1<-range( c(ergtheta1,ergtheta12) )
```

```
step<-10
index3<-seq(1,iter,step)
index4<-seq(burnin+1,iter,step)

plot(index3 , ergtheta0[index3], type='l', ylab='Values of mu',
xlab='Iterations', main='(c) Ergodic Mean Plot of mu', ylim=ylims0)
lines(index4, ergtheta02[index4-burnin], col=2, lty=2)

plot(index3, ergtheta1[index3], type='l', ylab='Values of sigma',
xlab='Iterations', main='(d) Ergodic Mean Plot of sigma', ylim=ylims1)
lines(index4, ergtheta12[index4-burnin], col=2, lty=2)

acf(theta[index2,1], main='Autocorrelations Plot for mu')
acf(theta[index2,2], main='Autocorrelations Plot for sigma')
```

[↓ Code](#)

1.4.1 The Slice Gibbs Sampler

切片Gibbs抽样(Slice Gibbs Sampler) 本质上是基于Gibbs抽样的. 其主要用
于当 完全的条件分布没有简单或者方便的形式情形. 这个方法通过添加一些
辅助变量 把参数空间扩大, 但保持感兴趣的边际分布不变, 而把所有的条件分
布转变成标准形式. 然后可以使用标准的Gibbs抽样方法.

切片Gibbs抽样的想法如下. 考虑目标分布 $g(x)$, 其很难进行抽样. 我们引
入一个新的辅助变量 u , 其条件分布为 $f(u|x)$. 则联合分布为

$$f(u, x) = f(u|x)g(x)$$

而 x 的边际分布等于目标分布 $g(x)$. 因此我们可以使用Gibbs算法从联合分布
 $f(u, x)$, 以及边际分布 $f(u)$ 和 $f(x) = g(x)$ 中产生随机数:

1. 产生 $u \sim f(u|x)$.
2. 产生 $x \sim f(u|x)g(x)$.

由于 $f(u|x)$ 在上述计算中出现两次, 因此其的选取要使得从分布 $f(u|x)$ 和 $f(u|x)g(x)$

中很方便的抽样，常用的一个选择是均匀分布 $U(0, g(x))$ ，此时

$$f(u, x) = \frac{1}{g(x)} g(x) I(0 < u < g(x)) = I(0 < u < g(x)),$$
$$f(x) = \int I(0 < u < g(x)) du = g(x).$$

因此，此时Gibbs抽样算法如下

1. 产生 $u^{(t)} \sim U(0, g(x^{(t-1)}))$;
2. 产生 $x^{(t)} \sim U(x : 0 \leq u^{(t)} \leq g(x))$.

对贝叶斯分析来说，经常选择 $u \sim U(0, f(y|\theta))$ ，联合分布为

$$f(\theta, u|y) \propto \left\{ \prod_{i=1}^n I(0 \leq u_i \leq f(y_i|\theta)) \right\} f(\theta)$$

从而Gibbs算法如下

1. 令 $\theta = \theta^{(t-1)}$.
2. 对 $i = 1, \dots, n$, 产生 $u_i^{(t)} \sim U(0, f(y_i|\theta))$.
3. 对 $j = 1, \dots, d$, 更新 $\theta_j \sim f(\theta_j | \prod_{i=1}^n I(0 \leq u_i^{(t)} \leq f(y_i|\theta)))$.

4. 令 $\theta^{(t)} = \theta$.

例 3 (切片Gibbs抽样: logistic回归中的应用) 考虑WAIS数据分析的例子.

我们选取辅助变量使得

$$f(u, \beta_0, \beta_1 | y) \propto \prod_{i=1}^n I(u_i \leq \frac{e^{\beta_0 y_i + \beta_1 x_i y_i}}{1 + e^{\beta_0 + x_i \beta_1}}) \exp\left(-\frac{(\beta_0 - \mu_{\beta_0})^2}{2\sigma_{\beta_0}^2} - \frac{(\beta_1 - \mu_{\beta_1})^2}{2\sigma_{\beta_1}^2}\right)$$

β_0, β_1 的边际分布为

$$\begin{aligned} f(\beta_0, \beta_1 | y) &= \int f(u, \beta_0, \beta_1 | y) du \\ &\propto \prod_{i=1}^n \frac{e^{\beta_0 y_i + \beta_1 x_i y_i}}{1 + e^{\beta_0 + x_i \beta_1}} \exp\left(-\frac{(\beta_0 - \mu_{\beta_0})^2}{2\sigma_0^2} - \frac{(\beta_1 - \mu_{\beta_1})^2}{2\sigma_1^2}\right). \end{aligned}$$

即为我们在第8讲例7中的模型. 因此我们使用切片Gibbs抽样方法

1. 对 $i = 1, \dots, n$, 从如下分布中产生 u_i ,

$$u_i | u_{-i}, \beta_0, \beta_1, y \sim U\left(0, \frac{e^{\beta_0 y_i + \beta_1 x_i y_i}}{1 + e^{\beta_0 + x_i \beta_1}}\right)$$

2. 从如下分布中产生 β_0 ,

$$\beta_0|u, \beta_1, y \sim N(\mu_{\beta_0}, \sigma_{\beta_0}^2) \prod_{i=1}^n I(u_i \leq \frac{e^{\beta_0 y_i + \beta_1 x_i y_i}}{1 + e^{\beta_0 + x_i \beta_1}}),$$

3. 从如下分布中产生 β_1 ,

$$\beta_1|u, \beta_0, y \sim N(\mu_{\beta_1}, \sigma_{\beta_1}^2) \prod_{i=1}^n I(u_i \leq \frac{e^{\beta_0 y_i + \beta_1 x_i y_i}}{1 + e^{\beta_0 + x_i \beta_1}}).$$

上述条件后验分布为截断的正态分布. 截断的区间定义为 $u_i \leq \frac{e^{\beta_0 y_i + \beta_1 x_i y_i}}{1 + e^{\beta_0 + x_i \beta_1}}$,
其可以重新表示为

$$For \ y_i = 1 \Rightarrow u_i \leq \frac{e^{\beta_0 + \beta_1 x_i}}{1 + e^{\beta_0 + x_i \beta_1}} \Rightarrow \beta_0 + \beta_1 x_i \geq \log \frac{u_i}{1 - u_i}$$

$$For \ y_i = 0 \Rightarrow u_i \leq \frac{1}{1 + e^{\beta_0 + x_i \beta_1}} \Rightarrow \beta_0 + \beta_1 x_i \leq \log \frac{1 - u_i}{u_i}$$

因此得到

$$\max_{i:y_i=1} (\log \frac{u_i}{1 - u_i}) \leq \beta_0 + \beta_1 x_i \leq \min_{i:y_i=0} (\log \frac{1 - u_i}{u_i})$$

对 β_0, β_1 解上述不等式得到

$$l_0 = \max_{i:y_i=1} (\log \frac{u_i}{1-u_i} - \beta_1 x_i) \leq \beta_0 \leq u_0 = \min_{i:y_i=0} (\log \frac{1-u_i}{u_i} - \beta_1 x_i)$$

以及

$$l_1 = \max_{i:y_i=1} (x_i^{-1} [\log \frac{u_i}{1-u_i} - \beta_0]) \leq \beta_1 \leq u_1 = \min_{i:y_i=0} (x_i^{-1} [\log \frac{1-u_i}{u_i} - \beta_0])$$

在此例中,所有的 $x_i > 0$. 因此参数 β_0, β_1 最终由分布 $N(\mu_{\beta_0}, \sigma_{\beta_0}^2)I(l_0, u_0)$ 和 $N(\mu_{\beta_1}, \sigma_{\beta_1}^2)I(l_1, u_1)$ 产生.

这里我们要从一个截断分布中产生随机数, 这并不困难. 事实上, 若要从如下截断分布中抽样

$$F_{[a,b]}^T(x) = P(X \leq x | a \leq X \leq b) = \frac{F(x) - F(a)}{F(b) - F(a)}, \quad \forall x \in [a, b]$$

则我们可以产生 $u \sim U(0, 1)$, 然后令 $u = F_{[a,b]}^T(x)$, 那么解此方程得到

$$x = F^{-1}(F(a) + u[F(b) - F(a)]).$$

因此实现如上分析的R代码如下

↑Code

```
y<-wais$senility; x<-wais$wais; n<-length(y)
positive<- y==1
Iterations<-55000
mu.beta<-c(0,0); s.beta<-c(100,100)
beta <- matrix(nrow=Iterations, ncol=2)
acc.prob <- 0
current.beta<-c(0,0); u<-numeric(n)
for (t in 1:Iterations){
  eta<-current.beta[1]+current.beta[2]*x
  U<-exp(y*eta)/(1+exp(eta))
  u<-runif( n, rep(0,n), U)
  logitu<-log( u/(1-u) )
  logitu1<- logitu[positive]
  logitu2<- -logitu[!positive]

  l0<- max( logitu1 - current.beta[2]*x[positive] )
  u0<- min( logitu2 - current.beta[2]*x[!positive] )
  unif.random<-runif(1,0,1)
  fa<- pnorm(l0, mu.beta[1], s.beta[1])
```

```

fb<- pnorm(u0, mu.beta[1], s.beta[1])
current.beta[1] <- qnorm( fa + unif.random*(fb-fa),
                           mu.beta[1], s.beta[1])

l1<- max( (logitu1 - current.beta[1])/x[positive] )
u1<- min( (logitu2 - current.beta[1])/x[!positive] )
unif.random<-runif(1,0,1)
fa<- pnorm(l1, mu.beta[2], s.beta[2])
fb<- pnorm(u1, mu.beta[2], s.beta[2])
current.beta[2] <- qnorm( fa + unif.random*(fb-fa),
                           mu.beta[2], s.beta[2])

beta[t,]<-current.beta
}
apply(beta[-(1:15000),],2,mean)
apply(beta[-(1:15000),],2,sd)

```

[↓Code](#)

链的收敛诊断图为

```

par( mfrow=c(3,2), xaxs='r', yaxs='r', bty='l' , cex=0.8)
iter<-55000

```

[↑Code](#)

```
burnin<-15000
index<-seq(1,iter,50)
index2<-(burnin+1):iter

plot(index, beta[index,1], type='l', ylab='Values of beta0',
      xlab='Iterations', main='(a) Trace Plot of beta0')
plot(index, beta[index,2], type='l', ylab='Values of beta1',
      xlab='Iterations', main='(b) Trace Plot of beta1')

iter<-55000
burnin<-15000
index<-seq(1,iter,1)
index2<-(burnin+1):iter

ergbeta0<-erg.mean( beta[index,1] )
ergbeta02<-erg.mean( beta[index2,1] )
ylims0<-range( c(ergbeta0,ergbeta02) )

ergbeta1<-erg.mean( beta[index,2] )
ergbeta12<-erg.mean( beta[index2,2] )
ylims1<-range( c(ergbeta1,ergbeta12) )
```

```

step<-50
index3<-seq(1,iter,step)
index4<-seq(burnin+1,iter,step)

plot(index3 , ergbeta0[index3], type='l', ylab='Values of beta0',
      xlab='Iterations', main='(c) Ergodic Mean Plot of beta0', ylim=ylims0)
lines(index4, ergbeta02[index4-burnin], col=2, lty=2)

plot(index3, ergbeta1[index3], type='l', ylab='Values of beta1',
      xlab='Iterations', main='(d) Ergodic Mean Plot of beta1', ylim=ylims1)
lines(index4, ergbeta12[index4-burnin], col=2, lty=2)

lag.to.print<-900
acf1<-acf(beta[index2,1], main='Autocorrelations Plot for beta0',
            lag.max=lag.to.print, plot=FALSE)
acf2<-acf(beta[index2,2], main='Autocorrelations Plot for beta1',

```

```
lag.max=lag.to.print, plot=FALSE)  
  
acf.index<-seq(1,lag.to.print,20)  
  
plot( acf1[acf.index], main='Auto-correlations for beta0' )  
plot( acf2[acf.index], main='Auto-correlations for beta1' )
```

↓Code

1.5 Monitoring Convergence

检查产生的链是否收敛, 最直接简单的就是图示了.

1.5.1 Convergence diagnostics plots

trace plot: 将所有生成的样本对迭代次数作图, 生成了链的一条样本路径图. 当链达到收敛时, 此路径图就应该呈现出稳定性, 没有明显的趋势和周期.

ergodic mean plot: MCMC方法的理论基础是遍历均值定理, 因此可以监

视遍历 均值是否达到收敛. 我们可以使用累积均值对迭代次数作图, 以观察遍历均值是否达到收敛.

Autocorrelation plot: 由于模型中的参数一般是相关的, 因此Gibbs抽样走遍目标 分布整个支撑的速度一般就会比较慢. 如果自相关水平很高, 则使用 *trace plot* 诊断链 的收敛性就比较差. 一般自相关随着步长的增大而减少, 如果某个链没有表现出这种现象, 那么说明链的产生机制有问题, 可能需要重新参数化.

1.5.2 Monte Carlo Error

在对MCMC生产的链进行分析时, Monte Carlo 误差 (MC 误差) 是需要监视的一个指标, 其衡量了估计量由于随机模拟 而带来的波动性. 在计算感兴趣的参数时, Monte Carlo误差必须很低且精度可以随着样本量递增. 其 和产生的样本量成反比, 因此用户自己可以控制. 从而增加迭代次数, 感兴趣的量就可以以递增 的精度被估计.

有两种计算MC误差的方法: *batch mean*和*windows estimator*. 第一种方法简单容易操作, 但是第二种方法精确.

使用*batch mean*方法时, 首先将生成的 T 个样本分成 K 个组(batch), 每个组 $v = T/K$ 个, K 常取为30或50. v 和 K 都要比较大, 以使得我们可以相合的估计方差以及减少自相关. 在计算 估计量 $g(X)$ 的MC误差时, 首先计算每个组内均值

$$\overline{g(X)}_b = \frac{1}{v} \sum_{t=(b-1)v+1}^{bv} g(X^{(t)}), \quad b = 1, \dots, K.$$

以及总的样本均值

$$\overline{\overline{g(X)}} = \frac{1}{K} \sum_{b=1}^K \overline{g(X)}_b.$$

因此均值的MC误差估计为

$$MCE(g(X)) = \hat{s}e(\overline{g(X)}) = \sqrt{\frac{1}{K(K-1)} \sum_{b=1}^k (\overline{g(X)}_b - \overline{\overline{g(X)}})^2}$$

MC误差的*batch mean*估计方法更多的讨论可以参见 Hastings (1970), Geyer (1992), Roberts (1996, p. 50), Carlin and Louis (2000, p. 172), and Givens and Hoeting (2005, p. 208).

window estimator 是基于Roberts (1996, p. 50)对自相关样本的样本方差表示

$$MCE(g(X)) = \frac{\hat{SD}(g(X))}{\sqrt{T}} \sqrt{1 + 2 \sum_{k=1}^{\infty} \hat{\rho}_k(g(X))},$$

其中 $\hat{\rho}_k g(X)$ 估计 $g(X^{(t)})$ 与 $g(X^{(t+k)})$ 之间的 k 阶自相关系数。很显然，对很大的 k ，自相关系数 $\hat{\rho}_k$ 由于样本量很少而不能很好的估计，而且对充分的 k ，自相关将接近 0。因此，取一个窗口 ω 使得其后的自相关系数都很小，在计算中就可以丢掉后面所有的值。这种基于窗口的 MC 误差为

$$MCE(g(X)) = \frac{\hat{SD}(g(X))}{\sqrt{T}} \sqrt{1 + 2 \sum_{k=1}^{\omega} \hat{\rho}_k(g(X))},$$

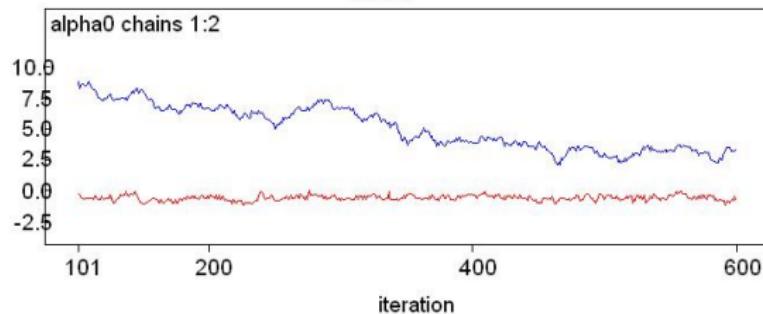
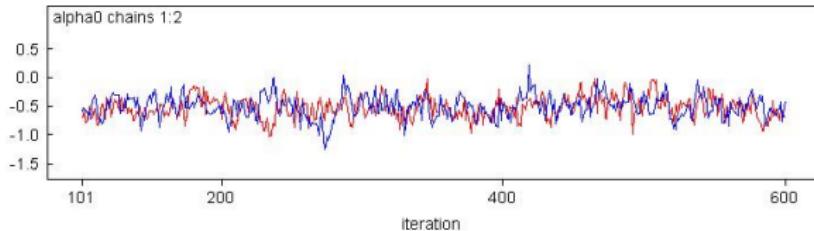
1.5.3 The Gelman-Rubin Method

Gelman & Rubin ¹ 给了一个例子, 说明 很慢的收敛不能通过单独检查一个链来发现. 单独一个链也许看起来已经收敛, 但是实际上在整个支撑上链没有达到收敛. 因为如果在目标分布的一个局部支撑上, 产生的值的方差非常小, 则就会出现这种情况. 因而 通过检查几个平行的链, 其初始值非常分散, 那么能发现收敛很慢的效率就会高得多. 这个方法是基于从不同的 初始值出发, 链达到平稳后, 应该表现的是一样的. 更准确的说, Gelman 和 Rubin 指出链内的方差和链 之间的方差应该是相同的.

这个想法可以通过将多个链的 *trace plot* 画在同一个图上来检查, 如下面的图

对于给定的一个链, 如果其已经达到收敛, 那么任何感兴趣的量 可以通过计算样本的样本均值和样本方差进行推断. 从而, k 个链就有 k 个可能的推断结

¹A. Gelman and D.B. Rubin. A single sequence from the Gibbs sampler gives a false sense of security. In J. M. Bernardo, J. O. Berger, O.P. Dawid, and A.F.M. Smith, editors, Bayesian Statistics 4, Pages 625-631. Oxford University Press, Oxford, 1992



果. 那么如果链已经收敛, 这些推断就应该比较类似. 因此Gelman和Rubin提出使用ANOVA的方法进行分析.

假设有 k 个链, 每个链有 n 个样本, 感兴趣的量为 ϕ , 其在目标分布下有期望 μ 和方差 σ^2 . 记 ϕ_{jt} 表示链 j 的第 t 个样本时 ϕ 的值, 那么在混合样本中, μ 的一个无偏估计为 $\hat{\mu} = \bar{\phi}_{..}$ 而链之间的方差 B/n 和链内的方差 W 分别为

$$\begin{aligned} B/n &= \frac{1}{k-1} \sum_{j=1}^k (\bar{\phi}_{j\cdot} - \bar{\phi}_{..})^2 \\ W &= \frac{1}{k(n-1)} \sum_{j=1}^k \sum_{t=1}^n (\phi_{jt} - \bar{\phi}_{j\cdot})^2 \end{aligned}$$

从而我们可以使用 B 和 W 加权进行估计 σ^2 :

$$\hat{\sigma}_+^2 = \frac{n-1}{n} W + \frac{B}{n}$$

如果初始值是从目标分布中抽取的, $\hat{\sigma}_+^2$ 就是 σ^2 的无偏估计. 但是如果 初始值过度分散, 则就会高估 σ^2 .

考虑到估计量 $\hat{\mu}$ 的抽样波动性, 方差的估计取为 $\hat{V} = \hat{\sigma}_+^2 + B/(kn)$.

比较混合和链内的推断可以通过

$$R = \frac{\hat{V}}{\sigma^2}$$

来进行. 称 \sqrt{R} 为 *scale reduction factor, SRF*. 我们可以估计 R 为

$$\hat{R} = \frac{\hat{V}}{W}.$$

称 $\sqrt{\hat{R}}$ 为 *potential scale reduction factor, PSRF*. 当链达到收敛时 并且产生的数据很大时, \hat{R} 应该趋于1. Gelman & Rubin 建议的修正统计量为 $\sqrt{\hat{R}} \frac{d}{d-2}$. 但此修正有误, Brooks and Gelman (1997)² 采用了一个修正的版本:

$$\hat{R}_c = \frac{d+3}{d+1} \hat{R}$$

² Brooks, SP. and Gelman, A. (1997) General methods for monitoring convergence of iterative simulations. Journal of Computational and Graphical Statistics, 7, 434-455.

其中 d 为 \hat{V} 的自由度的估计. 这个修正是很微小的, 因为在收敛时, d 会很大.

例 4 (Gelman-Rubin method) 目标分布为 $N(0, 1)$, 提议分布为 $N(X_t, \sigma^2)$,
 ϕ_{jt} 表示第 j 个链前 t 个样本的平均.

```
Gelman.Rubin <- function(psi) {  
  # psi[i,j] is the statistic psi(X[i,1:j])  
  # for chain in i-th row of X  
  psi <- as.matrix(psi)  
  n <- ncol(psi)  
  k <- nrow(psi)  
  psi.means <- rowMeans(psi)      #row means  
  B <- n * var(psi.means)        #between variance est.  
  psi.w <- apply(psi, 1, "var")  #within variances  
  W <- mean(psi.w)              #within est.  
  v.hat <- W*(n-1)/n + (B/(n*k))  #upper variance est.  
  r.hat <- v.hat / W            #G-R statistic  
  return(r.hat)  
}
```

↑Code

↓Code

↑Code

```
normal.chain <- function(sigma, N, X1) {  
  #generates a Metropolis chain for Normal(0,1)  
  #with Normal(X[t], sigma) proposal distribution  
  #and starting value X1  
  x <- rep(0, N)  
  x[1] <- X1  
  u <- runif(N)  
  for (i in 2:N) {  
    xt <- x[i-1]  
    y <- rnorm(1, xt, sigma)      #candidate point  
    r1 <- dnorm(y, 0, 1) * dnorm(xt, y, sigma)  
    r2 <- dnorm(xt, 0, 1) * dnorm(y, xt, sigma)  
    r <- r1 / r2  
    if (u[i] <= r) x[i] <- y else  
      x[i] <- xt  
  }  
  return(x)  
}
```

在下面的计算中, 方差 σ^2 取的很小, 当提议分布的方差相比于目标分布的方法很小时, 链混合的就会很慢.

```
sigma <- .2      #parameter of proposal distribution
k <- 4          #number of chains to generate
n <- 15000       #length of chains
b <- 1000        #burn-in length

#choose overdispersed initial values
x0 <- c(-10, -5, 5, 10)

#generate the chains
X <- matrix(0, nrow=k, ncol=n)
for (i in 1:k)
\  X[i, ] <- normal.chain(sigma, n, x0[i])

#compute diagnostic statistics
psi <- t(apply(X, 1, cumsum))
```

```

for (i in 1:nrow(psi))
    psi[i,] <- psi[i,] / (1:ncol(psi))
print(Gelman.Rubin(psi))

#plot psi for the four chains
par(mfrow=c(2,2))
for (i in 1:k)
    plot(psi[i, (b+1):n], type="l",
          xlab=i, ylab=bquote(psi))
par(mfrow=c(1,1)) #restore default

#plot the sequence of R-hat statistics
rhat <- rep(0, n)
for (j in (b+1):n)
    rhat[j] <- Gelman.Rubin(psi[,1:j])
plot(rhat[(b+1):n], type="l", xlab="", ylab="R")
abline(h=1.1, lty=2)

```

[↓ Code](#)

1.6 WinBUGS Introduction

BUGS(Bayesian inference Using Gibbs Sampling) 是使用MCMC算法进行Bayes计算的一个项目. WinBUGS 是该项目的一个软件产品. 目前WinBUGS的版本号为1.4.3.

WinBUGS所有的工作都是在一个*compound document*文档, 扩展名为.*odc*, 中进行. 该文档包含了模型程序代码, 数据, 以及可以将分析结果(图形,数据等)也保存在内. 下面我们来说明如何建立这样一个文档. 在WinBUGS里新建一个空白文档后(菜单File-New), 一个贝叶斯分析就从[建立模型, 数据, 初始值](#)三部分开始.

1.6.1 Building Bayesian models in WinBUGS

建立的一个Bayes模型, 包括: 指定似然和先验; 读入数据; 初始值. WinBUGS里模型里的参数/变量有三类:

1. 常量, 取固定值的量.

2. 随机部分, 通过一个概率分布来描述, 模型里的参数和响应变量都是随机变量, 分别通过先验分布和似然来描述. 随机部分 在进行MCMC算法时还要指定初始值.

3. 逻辑部分, 即通过一个数学表达式来刻画变量之间的关系.

模型的语法结构如下

```
model{  
variable~distribution(parameter1, parameter2,...)  
parameter1<-a+x*b  
a~distribution(a0,b0)  
b~distribution(a1,b1)  
parameter2~distribution(c,d)  
.....  
}
```

↑Code

↓Code

首先我们来介绍一下WinBUGS里 常用的数学函数, 和分布函数, 数学函

数作用在指定对象上后可以使用<-赋值到另外一个对象.

函数	意义
<code>abs(x)</code>	$ x $
<code>cloglog(x)</code>	$\log(-\log(1 - x))$
<code>cos(x)</code>	$\cos(x)$
<code>exp(x)</code>	$\exp(x)$
<code>equals(x1,x2)</code>	$f(x_1, x_2) = 1, x_1 = x_2; 0, otherwise$
<code>sin(x)</code>	$\sin(x)$
<code>inprod(x1[],x2[])</code>	$\sum_{i=1}^n x_1[i]x_2[i]$
<code>inverse(A[,])</code>	A^{-1}
<code>interp.lin(x,v1[],v2[])</code>	$v_{2i} + \frac{x - v_{1i}}{v_{1,i+1} - v_{1i}}(v_{2,i+1} - v_{2i})$
<code>logdet(A[,])</code>	$\log A $
<code>logfact(k)</code>	$\log(k!)$
<code>loggam(x)</code>	$\log\Gamma(x)$
<code>logit(x)</code>	$\log \frac{x}{1-x}$
<code>max(x1,x2)</code>	$\max(x_1, x_2)$
<code>min(x1,x2)</code>	$\min(x_1, x_2)$
<code>mean(x[])</code>	$\frac{1}{n} \sum_{i=1}^n x_i$
<code>sd(x[])</code>	$\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 / (n - 1)}$
<code>phi(x)</code>	$P(X \leq x), X \sim N(0, 1)$
<code>pow(x,z)</code>	x^z
<code>sqrt(x)</code>	\sqrt{x}
<code>sum(x[])</code>	$\sum_{i=1}^n x_i$
<code>rank(v[],k)</code>	$\sum_{i=1}^n I(v_i \leq v_k)$
<code>ranked(v[],k)</code>	$v_s : \sum_{i=1}^n I(v_i \leq v_s) = k$
<code>cut(x)</code>	posterior of x is not updated by the likelihood
<code>round(x)</code>	round x to the closest integer
<code>step(x)</code>	$f(x) = 1, x \geq 0; 0, otherwise$
<code>trunc(x)</code>	trunction to the closest smaller than x integer

分布函数可以参看WinBUGS菜单*help-user manual*, 然后点击打开的文档中的distribution连接查看. 另外, **for**循环也可以使用, 其和R里的用法相同.

1.6.2 Model specification in WinBUGS

模型的指定包括似然和先验两部分.

似然函数指定, 即指定相应变量的分布

$$y \sim \text{distribution}(\vartheta)$$

其中 ϑ 和一些解释变量有关系.

$$\vartheta = h(\theta, x_1, \dots, x_p)$$

因此似然函数为

$$f(y|\theta) = \prod_{i=1}^n f(y_i|\vartheta_i = h(\theta, x_{i1}, \dots, x_{pi}))$$

此似然函数在WinBUGS里的代码如下

```
model{  
    for(i in 1:n){  
        y[i]~distribution.name(parameter1[i],parameter2[i],...)  
        parameter1[i]<-function of theta and X's  
        parameter2[i]<-function of theta and X's  
        ...}  
}
```

↑Code

↓Code

先验指定 指定完似然后，紧接着需要指定参数的先验分布：

```
theta1~distribution.name  
theta2~distribution.name  
...  
...
```

↑Code

↓Code

1.6.3 Data and initial value specification

在WinBUGS里, 各种类型的数据是放在一个*list*里, 数据包括模型里 常变量的值, 如变量个数, 样本量等, 以及样本, MCMC算法的初始值等. 数据的读入可以通过两种方式: *rectangular*和*list*格式.

WinBUGS中的数值表示

1. 向量

1. $v[]$, 向量 v 的所有值.
2. $v[i]$, 向量 v 的第 i 个元素.
3. $v[a : b]$, 向量 v 的第 a 到第 b 个元素.

向量可以在*list*函数里使用函数c来创建.

2. 矩阵

1. $M[,]$, 矩阵M的所有元素
2. $M[i, j]$, 矩阵M的 ij 元素
3. $M[i,]$, 矩阵M的第*i*行所有元素
4. $M[, j]$, 矩阵M的第*j*列所有元素
5. $M[n : m, k : l]$, 矩阵M的第*n*至第*m*行, 第*k*至第*l*列所有元素

二维矩阵可以推广到多维数组. 对于矩阵元素的访问和运算和R中的运算基本相同, 但是在R中, 对整个矩阵操作只需使用其名称, 而在WinBUGS中, 需要使用名称`[.]`的形式. 创建矩阵的命令也不同, 在WinBUGS中, 创建一个矩阵的语法格式为

```
matrix.name=structure(  
  .Data=c(value1,value2,...,valuek),  
  .Dim=c(row.number,col.number)  
)
```

↑Code

[↓Code](#)

矩阵`matrix.name`是由`.Data`中的元素在`.Dim`规定下按照**行顺序**生成的。在上述语法中，`.Dim`如果是三维以上的，则就会创建多维数值。因此，在*R/Splus*中，使用

[↑Code](#)

```
> a<-structure(.Data=c(1:12), .Dim=c(3,4))#列顺序生成
> a
     [,1] [,2] [,3] [,4]
[1,]    1    4    7   10
[2,]    2    5    8   11
[3,]    3    6    9   12
```

[↓Code](#)

而在WinBUGS中，是按行顺序生成：

[↑Code](#)

```
> a
     [,1] [,2] [,3] [,4]
```

```
[1,]   1   2   3   4  
[2,]   5   6   7   8  
[3,]   9  10  11  12
```

[↓Code](#)

高维的数组也有这样的区别.

rectangular 格式

这种格式是使用数据的自然矩形形式. 其第一行为各变量的名称, 各变量的值以行排列的方式 排序, 最后一行以**END**结束, 并保持其后至少一个空行(1.4版本). 如

```
v1[]    v2[]    v3[]    v4[]    v5[]  
val11  val112 val113 val14  val15  
val21  val122 val123 val124 val125  
val31  val132 val133 val134 val135  
val41  val142 val143 val144 val145  
END
```

#空行

*list*格式, 类似于R里的list格式, 语法格式为

```
list(variable1=value, variable2=value,...)
```

其中取值可以是向量, 矩阵或者数组.

例 5 一个简单的数据指定例子 假如我们的数据如下

y	x1	x2	gender	age
12	2	0.3	1	20
23	5	0.2	2	21
54	9	0.9	1	23
32	11	2.1	2	20

我们需要加入两个变量: 样本量($n = 4$)和变量个数($p = 5$), 于是可以

```
list(n=4,p=5,y=c(12,23,54,32),x1=c(2,5,9,11),x2=c(0.3,0.2,0.9,2.1))
```

```
,gender=c(1,2,1,2),age=c(20,21,24,20))
```

如果需要使用矩阵形式, 则

```
list(n=4,p=5,datamatrix=structure(  
  .Data=c(12,2,0.3,1,20,23,5,0.2,2,  
  21,54,9,0.9,1,23,32,11,2.1,2,20),  
  .Dim=c(4,5)))
```

在WinBUGS里, 当模型完成编译后, 可以使用菜单*Info*里的*Node Info*来查看指定的对象.

使用*matrix*或者*array*还是不太方便, 好处是创建后数据格式后, 可以在编译模型时一次读入所有数据. 但是我们也可以使用下面这个方式, 分多次读入需要的数据:

```
y[] x1[] x2[] gender[] age[]
```

```
12    2   0.3    1      20
```

```
23      5   0.2      2       21  
54      9   0.9      1       23  
32     11   2.1      2       20
```

```
END
```

```
#空白行
```

这样可以使用*model specification tool*的*load*按钮多次读入需要的数据, 但是对于 模型中的一些常数, 比如样本量, 变量个数等, 需要再创建一个*list*对象来读入.

初始值用于初始化MCMC算法. 它们的格式和上述*list*格式相同.

例 6 一个完整的例子 假设我们有10个数据, 来自于总体 $N(\mu, \sigma^2)$, 我们想推断 μ, σ^2 . 先验分布为 $\mu \sim N(0, 100)$, $\sigma^2 \sim IG(0.01, 0.01)$. 则整个代码如下

```
model{  
    #likelihood  
    for(i in 1:n)
```

↑Code

```

y[i]~dnorm(mu,tau)
#prior
mu~dnorm(0,0.01)
tau~dgamma(0.01,0.01)
#deterministic definition of variance
sigma.squared<-1/tau
sigma<-sqrt(sigma.squared)
}

DATA
list(n=10,y=c(1.806, 2.04, 1.423, -2.814, -1.196,
-0.177, -0.233, -3.065, 0.871, 1.033))

INITIALS
list(mu=0,tau=1)

```

[↓Code](#)

这里需要注意的是在WinBUGS里, 正态分布 $N(\mu, \sigma^2)$ 中标准差的指定是通过其逆来指定. 另外, 在一个代码很长的文档中, 我们可以使用菜单*tools*里的*creat fold*命令来隐藏 指定部分的代码, 以节约屏幕空间.

1.6.4 Compiling model and simulating values

在模型和数据代码完成后, 我们需要对模型进行编译, 才能开始进行MCMC模拟. 其步骤可以列为下面几步:

1. 打开*model specification tool*
2. 检查模型的语法正确性.
3. 读入数据.
4. 编译模型.
5. 设置MCMC链的个数和初始值.
6. 运行MCMC算法, 产生随机数.
7. 使用*Inference*菜单里的*samples*来监视我们需要的参数.
8. 进行后续推断和分析.

例 7 检测煤矿灾难事件数据的变点 Poisson分布(过程)常被用来对某个事件发生次数进行建模. 考虑英国煤矿1851年3月15日至1962年3月22日之间10多个煤矿191次爆炸事故数据. 从下面的图可以看出, 在某一年后, 灾难事

件数明显减少，我们的目的就是估计这个变化点.

```
library(boot)      #for coal data  
data(coal)  
year <- floor(coal)  
y <- table(year)  
plot(y)  #a time plot
```

↑Code

↓Code

首先我们从数据集 $coal$ 中导出每年的爆炸次数数据:

```
y <- floor(coal[[1]])  
y <- tabulate(y)  
y <- y[1851:length(y)]
```

↑Code

↓Code

此即我们的观测数据. 对此计数数据, 考虑如下的模型

$$y_i \sim Poisson(\mu), i = 1, \dots, k;$$

$$y_j \sim Poisson(\lambda), j = i + 1, \dots, n.$$

即假设在某个年份(变点)之前, 灾难数服从一个Poisson分布, 而在此年后, 灾难数服从另一个Poisson分布. 对速率 μ 和 λ 使用 \log 函数表示. 因此, 在WinBUGS里的代码如下

```
model {  
for( i in 1 : n ) {  
    y[i] ~ dpois(mu[i])  
    log(mu[i]) <- b[1] + step(i - k) * b[2]  
}  
for (j in 1:2) {  
    b[j] ~ dnorm( 0.0,1.0E-6)  
}  
k ~ dunif(1,n)  
}
```

↑Code

↓Code

数据和初始值指定, 可以通过R里的函数**dput**来得到和WinBUGS里格式最

相近的一个形式，简单修改就可以得到

↑Code

DATA

```
list(n=112,y=c(4, 5, 4, 1, 0, 4, 3, 4, 0, 6, 3, 3, 4, 0, 2, 6, 3, 3, 5, 4,
5, 3, 1, 4, 4, 1, 5, 5, 3, 4, 2, 5, 2, 2, 3, 4, 2, 1, 3, 2, 2,
1, 1, 1, 1, 3, 0, 0, 1, 0, 1, 1, 0, 0, 3, 1, 0, 3, 2, 2, 0, 1,
1, 1, 0, 1, 0, 1, 0, 0, 2, 1, 0, 0, 0, 1, 1, 0, 2, 3, 3, 1,
1, 2, 1, 1, 1, 1, 2, 3, 3, 0, 0, 0, 1, 4, 0, 0, 0, 1, 0, 0, 0,
0, 0, 1, 0, 0, 1, 0, 1))
```

INITIALS

```
list(b=c(0,0),k=50)
```

↓Code

然后就可以进行MCMC模拟了。过程见课堂展示。

下面我们介绍另外一种方式。使用R里的包**R2WinBUGS**来进行。安装好WinBUGS 和此包后，就可以在R里使用WinBUGS进行贝叶斯分析了。在R里使用WinBUGS进行贝叶斯 分析的主要函数为**bugs**，其语法如下

↑Code

```
> model.sim <- bugs(data, inits, parameters, "model.bug")
```

↓Code

则WinBUGS就会在后台(默认)运行. 对上面的这个例子, 一种做法是首先将模型的代码存入一个文本文档, 比如 "coal.bug", 在R里执行的代码如下

```
> n=112
> y=c(4,5,4,1,0,4,3,4,0,6,
+ 3,3,4,0,2,6,3,3,5,4,5,3,1,4,4,1,5,5,3,4,2,5,2,2,3,4,2,1,3,2,
+ 1,1,1,1,1,3,0,0,1,0,1,1,0,0,3,1,0,3,2,2,
+ 0,1,1,1,0,1,0,1,0,0,0,2,1,0,0,0,1,1,0,2,
+ 2,3,1,1,2,1,1,1,1,2,4,2,0,0,0,1,4,0,0,0,
+ 1,0,0,0,0,0,1,0,0,1,0,0)
> data=list("n","y")
> parameters <- c("k","b")
> inits = function() {list(b=c(0,0),k=50)}
> coal.sim <- bugs (data, inits, parameters,
+ "coal.bug", n.chains=3, n.iter=10000,,bugs.directory="D:/WinBUGS14")
> attach.bugs(coal.sim)
> print(coal.sim)
```

↑Code

```
> par(mfrow=c(2,1))
> plot(density(b[,1]),xlab="beta1")
> plot(density(b[,2]),xlab="beta2")
```

[↓Code](#)

另外一种做法是使用R2WinBUGS包里的**write.model**函数，直接在R script里将模型存在临时目录里。然后就可以 使用bugs函数来读取了。

```
coal<-function(){
  for( i in 1 : n ) {
    y[i] ~ dpois(mu[i])
    log(mu[i]) <- b[1] + step(i - k) * b[2]
  }
  for (j in 1:2) {
    b[j] ~ dnorm( 0.0,1.0E-6)
  }
  k ~ dunif(1,n)
}
write.model(coal,"coal.bug")
coal.sim <- bugs (data, inits, parameters,
```

[↑Code](#)

```
"coal.bug", n.chains=3, n.iter=10000,,bugs.directory="D:/WinBUGS14")
```

[↓Code](#)

在R里还可以调用包[coda](#)来作更多的分析. 如绘制自相关图, 收敛诊断等等.
请参考*coda*的说明文档.