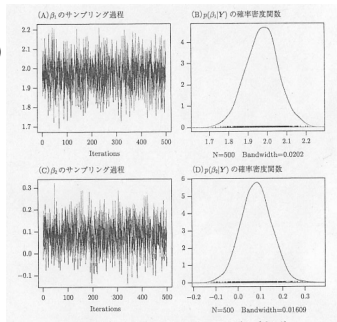


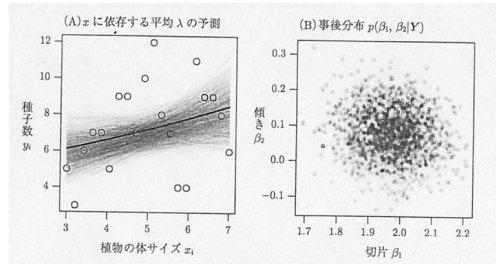


### MCMCサンプルから事後分布を推定

```
>post.list<- to.list(post.bugs)
>post.mcmc<-to.mcmc(post.bugs)
>s<-colnames(post.mcmc)
%in% c("beta1","beta2")
>plot(post.list[,s,])
```





### MCMCサンプルから事後分布を推定



- 1パラメータの事後分布からのサンプル $(\beta_1, \beta_2)$ の組み合わせごとの平均 $\lambda$ の予測。
- 2 `plot(as.matrix(post.mcmc)[,c("beta1","beta2")])`  
→  $\beta_1, \beta_2$ のMCMCサンプル間には強い相関がない

### 複数パラメータのMCMCサンプリング

- ギブスサンプリング
- $(\beta_1, \beta_2) = (1.5, 0)$
- $p(\beta_1 | Y, \beta_2 = 0.0) \propto \prod_i \frac{\lambda_i^{y_i} \exp(-\lambda_i)}{y_i!} p(\beta_1)$   
.....  $\lambda_i = \exp(\beta_1 + 0) \rightarrow$  新しい  $\beta_1 = 2.052 \rightarrow \lambda_i = \exp(2.052 + \beta_2 x_i)$
- $p(\beta_2 | Y, \beta_1 = 2.052) \propto \prod_i \frac{\lambda_i^{y_i} \exp(-\lambda_i)}{y_i!} p(\beta_2)$



$$p(\beta_2 | Y, \beta_1 = 2.052) \propto \prod_i \frac{\lambda_i^{y_i} \exp(-\lambda_i)}{y_i!} p(\beta_2)$$

以上のステップを繰り返す。

利点: 各MCMCステップにおいてもとの値と更新された値の相関がより小さい。