

MLG

Curso de Modelos Lineares Generalizado - DEST/UFMG
Marcos Oliveira Prates

17 de outubro de 2018

- Esquema de inferência:
 - Obter informação sobre um parâmetro de interesse desconhecido $\theta = (\theta_1, \dots, \theta_k)$
 - Usar a informação contida nas respostas \mathbf{Y}
 - Incluir informação a priori
- Portanto temos o seguinte esquema estocástico:
 - $\pi(\theta)$ = distribuição de probabilidade a priori
 - $\pi(\mathbf{y}|\theta)$ = verossimilhança

- Assim através do Teorema de Bayes obtemos

$$\begin{aligned}\pi(\theta|\mathbf{y}) &= \frac{\pi(\mathbf{y}, \theta)}{\pi(\mathbf{y})} = \frac{\pi(\mathbf{y}|\theta)\pi(\theta)}{\pi(\mathbf{y})} \\ &\propto \pi(\mathbf{y}|\theta)\pi(\theta)\end{aligned}$$

- Infelizmente não é possível fazer inferência sem a constante de normalização
- Apenas em casos muito simples, conseguimos obter essa constante
- **Desafio como amostrar então da distribuição a posteriori de θ ?**

- Veremos agora um exemplo desse tipo de método: **Amostrador de Gibbs ou Gibbs Sampling**.
- Nesse método amostramos um parâmetro, θ_j , de cada vez.
- Amostramos da distribuição condicional de um parâmetro quando os demais, $(\theta_1, \dots, \theta_{j-1}, \theta_{j+1}, \dots, \theta_k)$, são mantidos fixos.

- Seja (X, Y) um vetor aleatório.
- Vamos denotar sua distribuição conjunta por

$$f_{X,Y}(x,y).$$

- Como gerar amostras desse vetor?
- Podemos gerar X e Y independentemente, um ignorando o outro? Não.
- Suponha que sejamos capazes de encontrar as distribuições condicionais

$$f_{X|Y}(x|y) \quad f_{Y|X}(y|x).$$

- Seja (X, Y) um vetor aleatório.
- Vamos denotar sua distribuição conjunta por

$$f_{X,Y}(x, y).$$

- Como gerar amostras desse vetor?
- Podemos gerar X e Y independentemente, um ignorando o outro? Não.
- Suponha que sejamos capazes de encontrar as distribuições condicionais

$$f_{X|Y}(x|y) \quad f_{Y|X}(y|x).$$

- Especifique valores iniciais

$$X^{(0)} = x_0 \quad Y^{(0)} = y_0.$$

- Para i de 1 até B faça:
 - $X^{(i)} \sim f_{X|Y}(x^{(i-1)}|y^{(i-1)})$
 - $Y^{(i)} \sim f_{Y|X}(y^{(i-1)}|x^{(i)})$
- A partir de um B grande:
 - o vetor gerado $(x^{(i)}, y^{(i)})$ segue a distribuição $f_{X,Y}(x, y)$.
- Vejamos agora como aplicar o algoritmo para amostrar de distribuições a *posteriori*.

- Suponha que queremos gerar uma amostra da distribuição a *posteriori* de um vetor de parâmetro θ

$$\pi(\theta|\mathbf{y}).$$

- Iniciamos o algoritmo com um conjunto de valores iniciais arbitrários para o vetor

$$\theta^{(0)} = (\theta_1^{(0)}, \theta_2^{(0)}, \dots, \theta_k^{(0)}).$$

- Atualizamos cada um dos parâmetros $\theta_1, \theta_2, \dots, \theta_k$ de uma vez.
- Essas atualizações são feitas através das distribuições condicionais

$$\pi(\theta_j|\theta_{-j}, \mathbf{y}).$$

onde

$$\theta_{-j} = (\theta_1, \theta_2, \dots, \theta_{j-1}, \theta_{j+1}, \dots, \theta_k).$$

Passo 1

- Geramos

$$\theta_1^{(1)} \sim \pi(\theta_1 | \theta_2^{(0)}, \dots, \theta_k^{(0)}, \mathbf{y})$$

$$\theta_2^{(1)} \sim \pi(\theta_2 | \theta_1^{(1)}, \dots, \theta_k^{(0)}, \mathbf{y})$$

⋮

$$\theta_k^{(1)} \sim \pi(\theta_k | \theta_1^{(1)}, \dots, \theta_{k-1}^{(1)}, \mathbf{y})$$

Passo 2

- Geramos

$$\theta_1^{(2)} \sim \pi(\theta_1 | \theta_2^{(1)}, \dots, \theta_k^{(1)}, \mathbf{y})$$

$$\theta_2^{(2)} \sim \pi(\theta_1 | \theta_1^{(2)}, \dots, \theta_k^{(1)}, \mathbf{y})$$

⋮

$$\theta_k^{(2)} \sim \pi(\theta_1 | \theta_1^{(2)}, \dots, \theta_{k-1}^{(2)}, \mathbf{y})$$

Passo j

- Geramos

$$\theta_1^{(j)} \sim \pi(\theta_1 | \theta_2^{(j-1)}, \dots, \theta_k^{(j-1)}, \mathbf{y})$$

$$\theta_2^{(j)} \sim \pi(\theta_2 | \theta_1^{(j)}, \dots, \theta_k^{(j-1)}, \mathbf{y})$$

⋮

$$\theta_k^{(j)} \sim \pi(\theta_k | \theta_1^{(j)}, \dots, \theta_{k-1}^{(j)}, \mathbf{y})$$

Exemplo 1:

- Suponha que temos n observações
 $Y_i \sim \text{Poisson}(\lambda), \quad i = 1, \dots, n$
- Vamos definir $\lambda \sim \Gamma(\alpha, \beta)$
- Queremos fazer inferência sobre o parâmetro λ
- Portanto, precisamos calcular $\pi(\lambda|\mathbf{y})$.

- Vejamos como fica a distribuição a *posteriori* de λ (fazer no quadro)

$$\begin{aligned}\pi(\lambda|\mathbf{y}) &\propto \prod_{i=1}^n \frac{e^{-\lambda} \lambda^{y_i}}{y_i!} e^{-\lambda\beta} \lambda^{\alpha-1} \\ &\propto \lambda^{\sum_{i=1}^n y_i + \alpha - 1} e^{-\lambda(\beta+n)}\end{aligned}$$

- Portanto,

$$\lambda \sim \Gamma(\alpha + n\bar{y}, \beta + n)$$

- Como conhecemos a *posteriori* de λ podemos amostrar da distribuição

Exemplo 2:

- Suponha que temos N observações
 $Y_i \sim \text{Bin}(n_i, p), \quad i = 1, \dots, N$
- Vamos definir $p \sim \text{Beta}(\alpha, \beta)$
- Queremos fazer inferência sobre o parâmetro p
- Portanto, precisamos calcular $\pi(p|\mathbf{y})$.

- Vejamos como fica a distribuição a *posteriori* de λ (fazer no quadro)

$$\begin{aligned}\pi(p|\mathbf{y}) &\propto \prod_{i=1}^n p^{y_i} (1-p)^{n_i-y_i} p^{\alpha-1} (1-p)^{\beta-1} \\ &\propto p^{\sum_{i=1}^n y_i + \alpha - 1} (1-p)^{\sum_{i=1}^n (n_i - y_i) + \beta - 1}\end{aligned}$$

- Portanto,

$$p \sim \text{Beta}(\alpha + n \times \hat{y}, \beta + \sum_{i=1}^N (n_i - y_i))$$

- Como conhecemos a *posteriori* de p podemos amostrar da distribuição

- Até agora vimos como amostrar sequencialmente quando as condicionais completas possuem forma fechada.
- O que fazer quando elas não possuem? **Nesse caso utilizamos um passo de Metropolis**

- O passo de Metropolis consiste no seguinte:
 - Proponha uma distribuição conhecida $q(\theta_i)$ para gerar um candidato $\theta_i^{(t)*}$
 - Para testar se $\theta_i^{(t)*}$ é um bom candidato calcule

$$\text{ratio} = \frac{\pi(\theta_i^{(t)*} | (\theta_1^{(t+1)}, \dots, \theta_{i-1}^{(t+1)}, \theta_{i+1}^{(t)}, \dots, \theta_k^{(t)}), \mathbf{y}) q(\theta_i^{(t)*})}{\pi(\theta_i^{(t)} | (\theta_1^{(t+1)}, \dots, \theta_{i-1}^{(t+1)}, \theta_{i+1}^{(t)}, \dots, \theta_k^{(t)}), \mathbf{y}) q(\theta_i^{(t)})}$$

- Agora faça: Se $u < \min(1, \text{ratio})$ $\theta_i^{(t+1)} = \theta_i^{(t)*}$, se não $\theta_i^{(t+1)} = \theta_i^{(t)}$, onde $U \sim \text{Unif}(0, 1)$

- Suponha que temos N observações
 $Y_i \sim \text{Bin}(n_i, p_i)$, $i = 1, \dots, N$ e $\text{logit}(p_i) = \beta_0 + \beta_1 x_i$
- Escolha uma priori para β_0 e β_1 , e.g., $\beta_j \sim N(0, \sigma_j^2)$ $j = 0, 1$.
- Queremos fazer inferência sobre o parâmetro $\beta = (\beta_0, \beta_1)$
- Portanto, precisamos calcular $\pi(\beta|\mathbf{y})$.

- Para isso vamos utilizar o amostrador de Gibbs com passo de Metropolis pois a posteriori não possui forma fechada.

$$\pi(\beta|\mathbf{y}) \propto \prod_{i=1}^n \left(\frac{e^{\beta_0 + \beta_1 x_i}}{1 + e^{\beta_0 + \beta_1 x_i}} \right)^{y_i} \left(\frac{1}{1 + e^{\beta_0 + \beta_1 x_i}} \right)^{n_i - y_i} \prod_{j=1}^2 e^{-\frac{\beta_j^2}{2\sigma_j^2}}$$

- Portanto, a posteriori não possui forma fechada.
- Assim

$$\pi(\beta_0|\beta_1, \mathbf{y}) \propto \prod_{i=1}^n \left(\frac{e^{\beta_0 + \beta_1 x_i}}{1 + e^{\beta_0 + \beta_1 x_i}} \right)^{y_i} \left(\frac{1}{1 + e^{\beta_0 + \beta_1 x_i}} \right)^{n_i - y_i} e^{-\frac{\beta_0^2}{2\sigma_0^2}}$$

$$\pi(\beta_1|\beta_0, \mathbf{y}) \propto \prod_{i=1}^n \left(\frac{e^{\beta_0 + \beta_1 x_i}}{1 + e^{\beta_0 + \beta_1 x_i}} \right)^{y_i} \left(\frac{1}{1 + e^{\beta_0 + \beta_1 x_i}} \right)^{n_i - y_i} e^{-\frac{\beta_1^2}{2\sigma_1^2}}$$

- Como não conhecemos a constante de normalização não é possível amostrar diretamente da condicional completa.
- Vamos assim, utilizar o passo de Metropolis propondo $q(\beta_j^{(t)*}) = N(\beta_j(t), \sigma_j^2)$
- Dessa forma temos
 - Amostre $\beta_0^{(t+1)*}$
 - Calcule o ratio $= \frac{\pi(\beta_0^{(t+1)*} | \beta_1^{(t)} \mathbf{y})}{\pi(\beta_0^{(t)} | \beta_1^{(t)} \mathbf{y})} \frac{q(\beta_0^{(t)})}{q(\beta_0^{(t+1)*})}$
 - Faça $\beta_0^{(t+1)} = \beta_0^{(t+1)*}$ se $u < \text{ratio}$ e $\beta_0^{(t+1)} = \beta_0^{(t)}$ caso contrario

- Amostre $\beta_1^{(t+1)*}$
- Calcule o ratio $= \frac{\pi(\beta_1^{(t+1)*} | \beta_0^{(t+1)} \mathbf{y})}{\pi(\beta_1^{(t)} | \beta_0^{(t+1)} \mathbf{y})} \frac{q(\beta_1^{(t)})}{q(\beta_1^{(t+1)*})}$
- Faça $\beta_1^{(t+1)} = \beta_1^{(t+1)*}$ se $u < \text{ratio}$ e $\beta_1^{(t+1)} = \beta_1^{(t)}$ caso contrario
- Repita o procedimento B vezes.

- Atualmente existe uma variedade de programas capazes de fazer inferência Bayesiana de forma automática.
- Por exemplo
 - os pacotes *ars*, *MCMCpack*, *mcmc*, *INLA* , *NIMBLE*, *STAN* para o *R*
 - OpenBUGS, JAGS, MultiBUGS
 - SAS

- A aplicação desses software (pacotes) varia. O OpenBUGS oferece uma ferramenta bem flexível para representação hierárquica de modelos Bayesianos
- Para chamar o OpenBUGS de dentro do *R* alguns pacotes foram desenvolvidos: *rbugs*, *R2OpenBUGS* e *BRugs*
- O funcionamento do OpenBUGS depende de 3 arquivos bases
 - 1 Arquivo com o modelo a ser ajustado
 - 2 Arquivo com os dados
 - 3 Arquivo com os valores iniciais da cadeia de Markov

- A sintaxe do OpenBUGS é equivalente a sintaxe do *R*. Portanto, um exemplo de código para o modelo é:

```
model {  
  for (i in 1 : N) {  
    theta[i] ~ dgamma(alpha, beta)  
    lambda[i] <- theta[i] * t[i]  
    x[i] ~ dpois(lambda[i])  
  }  
  alpha ~ dexp(1)  
  beta ~ dgamma(0.1, 1.0)  
}
```

- O código `pumps.R` ensina como chamar o OpenBUGS de dentro do *R* através do *rbugs*