

# Algoritmos MCMC para inferência bayesiana (Parte 1)

Prof. Caio Azevedo

# Exemplo da normal bivariada

- Seja  $\mathbf{Y} = (Y_1, Y_2) \sim N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ . Desejamos estimar as fdp's marginais de  $Y_1, Y_2$ , com  $\boldsymbol{\mu}$  e  $\boldsymbol{\Sigma}$ , conhecidos.
- Sabemos que  $Y_i \sim N(\mu_i, \sigma_i^2), i = 1, 2$ .
- Suponha, no entanto, que saibamos apenas que:

$$Y_1|y_2, \boldsymbol{\mu}, \boldsymbol{\Sigma} \sim N_1(\bar{\mu}_1, \bar{\sigma}_1^2), \text{ em que } \bar{\mu}_1 = \mu_1 + \sigma_{12} (\sigma_2^2)^{-1} (y_2 - \mu_2) \text{ e } \bar{\sigma}_1^2 = \sigma_1^2 - (\sigma_{12})^2 (\sigma_2^2)^{-1}.$$



$$Y_2|y_1, \boldsymbol{\mu}, \boldsymbol{\Sigma} \sim N_1(\bar{\mu}_2, \bar{\sigma}_2^2), \text{ em que } \bar{\mu}_2 = \mu_2 + \sigma_{12} (\sigma_1^2)^{-1} (y_1 - \mu_1) \text{ e } \bar{\sigma}_2^2 = \sigma_2^2 - (\sigma_{12})^2 (\sigma_1^2)^{-1}.$$

- As distribuições condicionais podem ser utilizadas para estimar as distribuições marginais?



# Simulação iterativa

- Simule  $y_1^{(1)} \sim N(0, 1)$ , por exemplo. Com este valor, simule  $y_2^{(1)} | y_1^{(1)}, \boldsymbol{\mu}, \boldsymbol{\Sigma}$ .
- Repita o passo acima R vezes, obtendo-se  $(y_1^{(1)}, y_2^{(1)}), (y_1^{(2)}, y_2^{(2)}), \dots, (y_1^{(R)}, y_2^{(R)})$



# Histograma das amostras MCMC



# Gráficos das trajetórias (Trace plots) das amostras MCMC



# ACF das amostras MCMC



# Cadeias de Markov

- Estudo de sequências (conjuntos) de variáveis aleatórias que guardam alguma estrutura de dependência entre si.
- Exemplo: seja  $X_1, X_2, \dots$  um sequência de Bernoullis que representam resultados de lançamentos de duas moedas (0, cara ; 1, coroa).
- Caso  $X_i = 0$ , lança-se uma moeda com probabilidade de cara igual a 0,55, caso contrário lança-se uma moeda com probabilidade de cara igual à 0,35.

# Exemplo: lançamento de moedas

- Matriz de transição

$$\mathbf{P} = \begin{bmatrix} P(X_i = 0 | x_{i-1} = 0) & P(X_i = 1 | x_{i-1} = 0) \\ P(X_i = 0 | x_{i-1} = 1) & P(X_i = 1 | x_{i-1} = 1) \end{bmatrix}$$

$$\mathbf{P} = \begin{bmatrix} 0,55 & 0,45 \\ 0,35 & 0,65 \end{bmatrix}$$

- Distribuição estacionária:  $\mathbf{x} = \mathbf{P}\mathbf{x}$ .



## Exemplo: lançamento de moedas

- Resultado: Se a Cadeia de Markov (definida pela matriz de transição), for reversível, a distribuição estacionária existe e é única.
- Distribuição estacionária: Obtida através de observações da cadeia de Markov,  $\mathbf{x} = \mathbf{P}^n$ , para  $n$  suficiente grande.
- Neste caso  $\mathbf{x} = [0, 45; 0, 55]$

## Exemplo: normal bivariado

- No exemplo da normal bivariada, a matriz de transição (que possui um número infinito não enumerável de elementos) é definida pelas densidades de transição (distribuições condicionais completas):

$$Y_1|y_2, \boldsymbol{\mu}, \boldsymbol{\Sigma}; Y_2|y_1, \boldsymbol{\mu}, \boldsymbol{\Sigma}$$

- Neste caso, faz sentido calcular  $P(Y_1 \in a|y_2, \boldsymbol{\mu}, \boldsymbol{\Sigma})$  e  $P(Y_2 \in b|y_1, \boldsymbol{\mu}, \boldsymbol{\Sigma})$ , em que  $a, b$  são intervalos da reta.
- Resultado: se a Cadeia de Markov, com matriz de transição definida pelas condicionais completas, for reversível, sua distribuição estacionária será única e convergirá para as distribuições marginais de interesse.

# Algoritmos de Monte Carlo via Cadeias de Markov

- O conjunto de algoritmos que permitem simular variáveis aleatórias (iterativamente) a partir das distribuições condicionais completas é conhecido como algoritmos de Monte Carlo via Cadeias de Markov (MCMC).
- Monte Carlo (resolver integrais) Cadeias de Markov (gera cadeias de Markov).
- Aplicações: obter distribuições (marginais, condicionais, conjuntas) de interesse. Em particular: Inferência Bayesiana.

# Aplicações em Inferência Bayesiana

- Distribuição inversa gama  $X \sim IG(r, \gamma)$ :

$$p(x) = \frac{\gamma^r}{\Gamma(r)} e^{-x/\gamma} x^{-(r+1)} \mathbb{1}_{(0, \infty)}(x)$$

- Distribuição normal-inversa gama  $(X, Y) \sim NIG(\mu, \nu, r, \gamma)$

$$X|y \sim N(\mu, y/\nu)$$

$$Y \sim IG(r, \gamma)$$

# Continuação

## ■ Densidade conjunta

$$p(x, y) = \frac{\sqrt{\nu}}{\sqrt{2\pi}} y^{-1/2} y^{-(r+1)} \exp\left(-\frac{\gamma}{y}\right) \exp\left\{-\frac{1}{2} \frac{\nu(x-\mu)^2}{\sigma^2}\right\} \\ \times \mathbb{1}_{(0, \infty)}(y) \mathbb{1}_{(-\infty, \infty)}(x)$$

## ■ Distribuição marginal de $X$ , $X \sim t_{(2r)}\left(\mu, \sqrt{\frac{\gamma}{r\nu}}\right)$ ,

$$p(x) = \frac{\Gamma\left(\frac{2r+1}{2}\right)}{\Gamma\left(\frac{2r}{2}\right)\Gamma\left(\frac{1}{2}\right)} (\sqrt{2r}\delta)^{-1} \left[1 + \frac{(x-\mu)^2}{2r\delta^2}\right]^{-\frac{2r+1}{2}} \mathbb{1}_{(-\infty, \infty)}(x) \\ \delta^2 = \sqrt{\frac{\gamma}{r\nu}}$$

# Aplicações em Inferência Bayesiana

- Seja  $X_1|\boldsymbol{\theta}, \dots, X_n|\boldsymbol{\theta}, \boldsymbol{\theta} = (\mu, \sigma^2)$  uma amostra aleatória de  $X|\boldsymbol{\theta} \sim N(\mu, \sigma^2)$ .
- Família conjugada (normal inversa gama)

$$\mu|\sigma^2 \sim N(\alpha, \sigma^2/\kappa)$$

$$\sigma^2 \sim \text{IG}(\gamma, \beta)$$

# Continuação

- Posteriori conjunta

$$\mu|\mathbf{x}, \sigma^2 \sim N(\alpha^*, \sigma^2/\nu^*)$$

$$\sigma^2|\mathbf{x} \sim \text{IG}(r^*, \gamma^*)$$

em que  $\nu^* = \nu + n$ ,  $\gamma^* = \frac{1}{2} \left[ \frac{n\nu}{n+\nu} (\bar{x} - \alpha)^2 + (n-1)s^2 + \gamma \right]$ ,

$$r^* = \frac{n}{2} + r.$$

- Além disso,  $\mu|\mathbf{x} \sim t_{(2r^*)} \left( \alpha^*, \sqrt{\frac{\gamma^*}{r^*\nu^*}} \right)$ .

- Assim, as posterioris marginais são:  $\mu|\mathbf{x} \sim t_{(2r^*)} \left( \alpha^*, \sqrt{\frac{\gamma^*}{r^*\nu^*}} \right)$  e  $\sigma^2|\mathbf{x} \sim \text{IG}(r^*, \gamma^*)$ .

# Continuação

- Pode-se provar que (distribuições condicionais completas):

$$\mu | \mathbf{x}, \sigma^2 \sim N(\alpha^*, \sigma^2 / \nu^*)$$

$$\sigma^2 | \mathbf{x}, \mu \sim \text{IG}(r^{**}, \gamma^{**})$$



em que

$$r^{**} = \frac{n+1}{2} + r; \gamma^{**} = \frac{n}{2} (\bar{x} - \mu)^2 + \frac{\nu}{2} (\mu - \alpha)^2 + \frac{1}{2}(n-1)s^2 + \gamma$$



$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i; s^2 = \frac{1}{n-2} \sum_{i=1}^n (x_i - \bar{x})^2.$$





# Histograma das amostras MCMC



# Gráficos das trajetórias (Trace plots) MCMC



# ACF das amostras MCMC



# Definição geral dos algoritmos MCMC

- Seja  $p(\boldsymbol{\theta}|\mathbf{x}) \propto p(\mathbf{x}|\boldsymbol{\theta})p(\boldsymbol{\theta})$  a distribuição a posteriori de interesse (com forma analítica intratável).
- Considere a seguinte partição para o (vetor) p-paramétrico  $\boldsymbol{\theta} = (\boldsymbol{\theta}_1, \boldsymbol{\theta}_2, \dots, \boldsymbol{\theta}_k), k \leq p$ .
- Sejam  $\theta_j | \boldsymbol{\theta}_{(-j)}, \mathbf{x}, i = 1, 2, \dots, k$  em que  $\boldsymbol{\theta}_{(-j)}$  denota o vetor paramétrico  $\boldsymbol{\theta}$  menos a componente  $\boldsymbol{\theta}_j$ , as **distribuições condicionais completas**.

# Definição geral dos algoritmos MCMC

- Inicie a cadeia com um conjunto de valores apropriados (respeitando o espaço paramétrico).
- Para  $r = 1, 2, \dots, R$ ,  $j = 1, 2, \dots, k$  simule  $\theta_j^{(r)}$  de  $\theta_j | \theta_{(-j)}^{(r-1)}, \mathbf{x}$ .
- A partir de algum  $B > 1$  (burn-in), retenha os valores a cada  $t$  (espaçamento) iterações (para evitar a presença de autocorrelação).
- Os valores retidos, se a cadeia tiver alcançado a convergência, corresponderá à uma amostra aleatória das posteriores (distribuições) de interesse.

# Questões de interesse (verificação da convergência)

- 1 Como simular de  $\theta_j$  caso a distribuição condicional completa não seja conhecida ou possível de simular diretamente?
- 2 Como verificar a convergência da cadeia gerada?
- 3 Como determinar  $B, t, R$ ?

# Ferramentas para verificação de convergência

- Simular diferentes cadeias, a partir de valores iniciais diferentes.
- Colocar, num mesmo gráfico, as trajetórias (trace plots) de todas as cadeias, para cada parâmetros  $(B,t,R)$ .
- Gráficos de autocorrelação  $(t)$ .
- Acompanhar, visualmente, a evolução de momentos e/ou quantis, calculados desde o primeiro valor gerado até a iteração  $r$ , para cada valor de  $r$   $(B,R)$ .
- Estatística de Geweke: teste de igualdade de médias para sub-amostras disjuntas de uma única cadeia  $(B,R)$ .
- Estatística de Gelman-Rubin: análise de variância entre as cadeias geradas  $(B,R)$ .

# Estatística de Geweke (EG)

- Considere uma única cadeia (para cada parâmetro).
- A primeira metade da cadeia é subdividida em  $b$  intervalos disjuntos (com aproximadamente o mesmo tamanho).
- Selecionam-se amostras de tamanho  $n_1$  e  $n_2$ , da primeira e segunda metades respectivamente.
- Seja  $\bar{\theta}_1 = \frac{1}{n_1} \sum_{r=1}^{n_1} \theta_1^{(r)}$  e  $\bar{\theta}_2 = \frac{1}{n_2} \sum_{r=1}^{n_2} \theta_2^{(r)}$  (valores simulados).
- $EG = \frac{\bar{\theta}_1 - \bar{\theta}_2}{\sqrt{\frac{\hat{s}_1(0)}{n_1} + \frac{\hat{s}_2(0)}{n_2}}}$   
em que  $\hat{s}_i^2(0)$  é a variância da amostra calculada pela estimativa consistente da densidade espectral na frequência zero (por causa de possível existência de autocorrelação), da amostra  $i$ .



# Estatística de Geweke (EG)

- Repete-se o processo acima, descartando-se o primeiro subintervalo da primeira metade da cadeia.
- Repete-se, uma segunda vez, descartando-se os dois primeiros subintervalos da primeira metade da cadeia.
- Repete-se o processo até ficar-se com somente o último subintervalo.
- Espera-se, se a cadeia tiver convergido, que a partir de um determinado “descarte”, as estatísticas não sejam mais significativas (estejam entre  $(-2,2)$ ).

# Estatística de Gelman Rubin (EGR)

- Consiste em uma análise de variância considerando M diferentes cadeias para cada parâmetro.
- Defina

$$W = \frac{1}{M} \sum_{j=1}^M s_j^2; s_j^2 = \frac{1}{R-1} \sum_{r=1}^R \left( \theta_j^{(r)} - \bar{\theta}_j \right)^2; \bar{\theta}_j = \frac{1}{R} \sum_{r=1}^R \theta_j^{(r)}$$

$$V = \frac{R}{M-1} \sum_{j=1}^M \left( \bar{\theta}_j - \bar{\bar{\theta}} \right)^2; \bar{\bar{\theta}} = \frac{1}{M} \sum_{j=1}^M \bar{\theta}_j$$

$$\widehat{Var}(\theta) = \left( 1 - \frac{1}{R} \right) W + \frac{M+1}{MR} V; R_c = \sqrt{\frac{\widehat{d} + 3}{\widehat{d} + 1} \frac{\widehat{Var}(\theta)}{W}}$$

# Estatística de Gelman Rubin (EGR)

- É possível provar que  $R_c \geq 1$ . Em geral, se  $R_c \leq 1,2$ , então a cadeia convergiu.
- Na prática: cada cadeia (para cada parâmetro) é subdividida em intervalos. Calcula-se a estatística  $R_c$  utilizando o primeiro intervalo (descartando-se a primeira metade) de todas as  $M$  cadeias. Depois, calcula-se  $R_c$  utilizando-se os dois primeiros intervalos (descartando-se a primeira metade do intervalo resultante), depois os três primeiros (descartando-se a primeira metade do intervalo resultante), assim por diante.
- Analisa-se o comportamento da estatística (calculando-se um intervalo de confiança) ao longo desse processo.

# Modelo gama

- Exemplo: posteriori associada ao modelo gama( $r, \lambda$ ).
- Suponha uma amostra aleatória de tamanho  $n$  de  $X|r, \lambda \sim \text{gama}(r, \lambda)$ , com  $r$  conhecido.

$$p(x|r) = \frac{1}{\lambda^r \Gamma(r)} e^{-x/\lambda} x^{r-1} \mathbb{1}_{(0, \infty)}(x)$$

- Priori:  $p(r)$  alguma fdp com suporte em  $\mathcal{R}^+$ .
- Verossimilhança:

$$p(\mathbf{x}|r) = \frac{1}{\lambda^{nr} \Gamma(r)^n} e^{-n\bar{x}/\lambda} \prod_{i=1}^n x_i^{r-1}$$

# Priori e posteriori

- Priori ( $r \sim \text{gama}(\alpha, \gamma)$  e  $\lambda \sim \text{IG}(\delta, \phi)$ ).

$$\begin{aligned}
 p(r, \lambda) = p(r)p(\lambda) &= \frac{1}{\gamma^\alpha \Gamma(\alpha)} e^{-r/\gamma} r^{\alpha-1} \mathbb{1}_{(0, \infty)}(r) \\
 &\times \frac{\phi^\delta}{\Gamma(\phi)} e^{-\phi/\lambda} \lambda^{-\delta-1} \mathbb{1}_{(0, \infty)}(\lambda)
 \end{aligned}$$

- Posteriori

$$\begin{aligned}
 p(r, \lambda | \mathbf{x}) &\propto \frac{1}{\lambda^{nr} \Gamma(r)^n} e^{-n\bar{x}/\lambda} \prod_{i=1}^n x_i^{r-1} \times e^{-r/\gamma} r^{\alpha-1} \\
 &\times e^{-\phi/\lambda} \lambda^{-\delta-1} \mathbb{1}_{(0, \infty)}(r) \mathbb{1}_{(0, \infty)}(\lambda)
 \end{aligned}$$

# Distribuições condicionais completas

- Condicionais completas

$$p(r|\lambda, \mathbf{x}) \propto \frac{1}{\lambda^{nr} \Gamma(r)^n} \prod_{i=1}^n x_i^{r-1} \times e^{-r/\gamma} r^{\alpha-1}$$

$$p(\lambda|r, \mathbf{x}) \propto e^{-(n\bar{x}+\phi)/\lambda} \lambda^{-nr-\delta-1}$$

- Note que:  $\lambda|r, \mathbf{x} \sim \text{IG}(nr + \delta, n\bar{x} + \phi)$  mas  $r|\lambda, \mathbf{x}$  não corresponde à nenhuma distribuição catalogada.
- Algoritmo: simular, iterativamente, valores para  $(r, \lambda)$  através das duas distribuições acima.

# Simulação das distribuições condicionais completas

- Se todas as distribuições condicionais completas forem conhecidas e fáceis de simular, teremos o algoritmo do amostrador de Gibbs (“Gibbs sampling”).
- Como no exemplo anterior da distribuição normal.
- Ponto importante, identificada a distribuição condicional completa, eg, normal, inversa gama, t de Student, devemos escolher algoritmos apropriados para simular delas (eg, transformada inversa, rejeição, rejeição adaptativa, amostragem por importância).

# Simulação das distribuições condicionais completas

- Caso alguma(a) distribuição(ões) condicional(is) completa(s) não seja(m) “conhecida(s)”, algum algoritmo auxiliar para simular valores dela tem de ser usado: Metropolis-Hastings, rejeição adaptativa, amostragem por corte etc.



# Amostrador de Gibbs

- Inicie as cadeias com valores iniciais conveniente.
- Simule, para  $r=1,2,\dots,R$ :
  - 1  $\theta_1^{(r)}$  de  $\theta_1^{(r)} | \theta_2^{(r-1)}, \theta_3^{(r-1)}, \dots, \theta_k^{(r-1)}, \mathbf{x}$ .
  - 2  $\theta_2^{(r)}$  de  $\theta_2^{(r)} | \theta_1^{(r)}, \theta_3^{(r-1)}, \dots, \theta_k^{(r-1)}, \mathbf{x}$ .
  - 3  $\theta_3^{(r)}$  de  $\theta_3^{(r)} | \theta_1^{(r)}, \theta_2^{(r)}, \dots, \theta_k^{(r-1)}, \mathbf{x}$ .
  - $\vdots$
  - 4  $\theta_k^{(r)}$  de  $\theta_k^{(r)} | \theta_1^{(r)}, \theta_2^{(r)}, \dots, \theta_{k-1}^{(r)}, \mathbf{x}$ .

# WinBUGS

- Programa WinBugs: permite ajustar modelos complexos usando diversos algoritmos do tipo MCMC.
- Em geral, basta apenas fornecer o modelo (verossimilhança) e prioris.
- Limitações no uso de prioris impróprias (Jeffreys).
- Dispõe de mecanismos para inserir verossimilhanças e prioris que não são padrão (não constam em seu banco de dados).
- Pode ser utilizado de modo mais simples através do pacote *R2WinBUGS* do R.
- O diagnóstico de convergência pode ser facilmente realizado através do pacote *coda*, disponível no programa R.

# Algoritmos para simular das cond.(tradução do manual)

- Condicional completa contínua
  - Conjugada (conhecida): amostragem direta usando algoritmos padrão.
  - Log-côncava: Rejeição adaptativa de derivação livre (Gilks, 1992).
  - Espaço paramétrico restrito: Amostragem por corte (“slice-sampling”), Neal, 1997.
  - Espaço paramétrico irrestrito: Metropolis-Hastings (adaptativo).
- Condicional completa discreta
  - Limite superior finito: transformada inversa.
  - Poisson deslocada: amostragem direta usando algoritmos padrão.

# Comparação de modelos

- Seja  $h(\boldsymbol{\theta}) = -2 \ln p(\mathbf{x}|\boldsymbol{\theta})$ ,  $\boldsymbol{\theta} = (\theta_1, \dots, \theta_k)$  (quanto menor, melhor o ajuste do modelo).
- Seja  $\boldsymbol{\theta}^{(1)}, \boldsymbol{\theta}^{(2)}, \dots, \boldsymbol{\theta}^{(s)}$ , uma amostra MCMC válida de tamanho  $s$ .  
Defina:  $\bar{\boldsymbol{\theta}} = (\bar{\theta}_1, \dots, \bar{\theta}_k)$ , em que  $\bar{\theta}_j = \frac{1}{s} \sum_{r=1}^s \theta_j^{(r)}$ ,  $j = 1, 2, \dots, k$ .
- Defina ainda: Deviance =  $\bar{D} = \frac{1}{s} \sum_{r=1}^s h(\boldsymbol{\theta}^{(s)})$  e  $\hat{D} = h(\bar{\boldsymbol{\theta}})$ .
- Estatística de comparação de ajuste de modelos: Deviance,  $p_D = \bar{D} - \hat{D}$  e  $DIC = \bar{D} + p_D$ .

# Comparação de modelos

- Quanto maior o valor de  $p_D$  e menor os valores do *Deviance* e do *DIC* melhor o ajuste do modelo. O WinBUGS calcula ambos.
- Atenção: mesmo o modelo que apresenta o melhor ajuste (segundo os critérios acima) pode não estar bem ajustado aos dados. Faz-se necessário, sempre, a verificação de qualidade de ajuste do modelo eleito por análise de resíduos, distribuição preditiva, etc.

# Voltando ao exemplo da potência das turbinas de aviões


- Prioris  $r \sim \text{gama}(0, 01; 1/0, 01)$ ,  $\mathcal{E}(R) = 1$ ,  $\mathcal{V}(R) = 100$  e  $\lambda \sim \text{IG}(0, 01; 0, 01)$  (vaga).
- Algoritmo WinBUGS para o ajuste do modelo.

```


ComTurb
gamamodel<-function(){
  for (i in 1 : N){
    y[i]~dgamma(r, lambdaa)
  }
  r~dgamma(0.01,0.01)
  lambdaa~dgamma(0.01,0.01)
  lambda<-pow(lambdaa, -1)
}

```

# Traceplots para os três conjuntos de cadeias geradas




# Autocorrelações para um dos conjuntos de cadeias









# Gráfico das medianas acumuladas para um dos conjuntos de cadeias





# Gráfico da estatística de Geweke para um dos conjuntos de cadeias



# Gráfico da estatística de Gelman-Rubin utilizando os três conjuntos de cadeias



# Histograma da amostra válida para um dos conjuntos de cadeias



# Estimativas Bayesianas para um dos conjuntos de cadeias

## ■ Resumo

Estatística	Parâmetro	
	$r$	$\lambda$
EAP	3,92	2,66
EPAP	0,76	0,59
$IC_B(95\%)$	[ 2,55; 5,47]	[ 1,75; 4,15]
$HPD(95\%)$	[ 2,47; 5,39]	[1,62;3,87]

- Modelo gama: Deviance = 295,7;  $p_D = 2,1$ ;  $DIC = 297,7$ . Modelo exponencial Deviance = 331,0;  $p_D = 1,0$ ;  $DIC = 332,1$ .

## Voltando ao exemplo do número acidentes

- Modelo proposto para analisar os dados: Considere ( $i = 1$ , ano de 1961,  $i=2$ , ano de 1962). Lembrando que: 1961 (sem limite de velocidade) 1962 (com limite de velocidade), temos

$$Y_{ij} | \beta \stackrel{ind.}{\sim} \text{Poisson}(\mu_i), i = 1, 2, j = 1, \dots, 43$$


$$\ln \mu_i = \mu + \alpha_i, \alpha_1 = 0$$

em que  $\beta = (\mu, \alpha_2)'$ . Assim, concluí-se que  $\mathcal{E}(Y_{ij} | \beta) = e^{\mu + \alpha_i}$ .

# Medidas Resumo



Ano	Média	Var.	DP	CV(%)	Mín.	Med.	Máx.
1961	26,05	82,66	9,09	34,91	8,00	25,00	47,00
1962	18,05	44,71	6,69	37,05	7,00	17,00	41,00

# Boxplots do número de acidentes por ano








# Histogramas do número de acidentes por ano




# Traceplots para os três conjuntos de cadeias geradas





# Autocorrelações para um dos conjuntos de cadeias





# Gráfico das medianas acumuladas para um dos conjuntos de cadeias





# Gráfico da estatística de Geweke para um dos conjuntos de cadeias



# Gráfico da estatística de Gelman-Rubin utilizando os três conjuntos de cadeias



# Histograma da amostra válida para um dos conjuntos de cadeias



# Estimativas Bayesianas para um dos conjuntos de cadeias


## ■ Resumo

Parâmetro	EAP	DPAP	$IC_B(95\%)$	$HPD(95\%)$
$\mu$	3,25	0,03	[3,20 ; 3,32]	[3,20 ; 3,32]
$\alpha_2$	-0,37	0,05	[-0,46 ; -0,28]	[-0,46 ; -0,28]
$\mu_1 = \exp(\mu)$	26,05	0,79	[24,58 ; 27,58]	[24,58 ; 27,58]
$\mu_2 = \exp(\mu + \alpha_2)$	18,04	0,67	[ 16,73 ; 19,30 ]	[16,68 ; 19,22 ]

- Modelo com  $\alpha_2$ : Deviance = 654,8,  $p_D = 1,8$ ;  $DIC = 656,6$ . Modelo sem  $\alpha_2$ : Deviance= 716,7  $p_D = 1,0$ ;  $DIC = 717,8$ .




# Posteriors das médias de cada grupo




# Valores observados e distribuições preditivas

Frequências observadas e preditas sob cada uma das priors



Frequências observadas e preditas sob cada uma das priors



# Outro modelo para analisar o exemplo do número acidentes

- Modelo proposto para analisar os dados: Considere ( $i = 1$ , ano de 1961,  $i=2$ , ano de 1962). Lembrando que: 1961 (sem limite de velocidade) 1962 (com limite de velocidade), temos

$$Y_{ij} | \beta, b_i \stackrel{ind.}{\sim} \text{Poisson}(\mu_{ij}), i = 1, 2, j = 1, \dots, 43$$

$$\ln \mu_{ij} = \mu + \alpha_i + b_j, \alpha_1 = 0$$

$$b_j \stackrel{i.i.d.}{\sim} N(0, \sigma^2)$$

em que  $\beta = (\mu, \alpha_2, \sigma^2)'$ .

# Outro modelo para analisar o exemplo do número acidentes

- Se  $b_j \sim N(0, \sigma^2)$ , então  $e^{b_j} \sim \text{log-normal}(0, \sigma^2)$
- Neste caso,




$$\mathcal{E}(Y_{ij} | \beta, \sigma^2) \equiv \mathcal{E}(Y_{ij}) = \mathcal{E}(\mathcal{E}(Y_{ij} | b_j)) = e^{\mu + \alpha_i} \mathcal{E}(e^{b_j}) = e^{\mu + \alpha_i} e^{\sigma^2/2} > e^{\mu + \alpha_i}$$

e




$$\begin{aligned} \mathcal{V}(Y_{ij}) &= \mathcal{V}(\mathcal{E}(Y_{ij} | b_j)) + \mathcal{E}(\mathcal{V}(Y_{ij} | b_j)) = e^{2(\mu + \alpha_i)} \mathcal{V}(e^{b_j}) + e^{\mu + \alpha_i} \mathcal{E}(e^{b_j}) \\ &= e^{2(\mu + \alpha_i)} (e^{\sigma^2} - 1) e^{\sigma^2/2} + e^{\mu + \alpha_i} e^{\sigma^2/2} > e^{\mu + \alpha_i} \end{aligned}$$

- Assim, o modelo em questão consegue contemplar uma variância maior do que aquela apresentada pelo modelo de regressão de Poisson.




# Traceplots para os três conjuntos de cadeias geradas






# Autocorrelações para um dos conjuntos de cadeias



# Gráfico das medianas acumuladas para um dos conjuntos de cadeias






# Gráfico da estatística de Geweke para um dos conjuntos de cadeias








# Gráfico da estatística de Gelman-Rubin utilizando os três conjuntos de cadeias



# Histograma da amostra válida para um dos conjuntos de cadeias




# Estimativas Bayesianas para um dos conjuntos de cadeias

## ■ Resumo

Parâmetro	EAP	DPAP	$IC_B(95\%)$	$HPD(95\%)$
$\mu$	3,22	0,05	[3,12 ; 3,33]	[3,11 ; 3,31]
$\alpha_2$	-0,37	0,08	[-0,51 ; -0,22]	[-0,51 ; -0,23]
$\sigma^2$	0,08	0,02	[ 0,05 ; 0,13]	[0,05 ; 0,13]
$\mu_1 = e^\mu e^{\sigma^2/2}$	26,07	1,43	[23,46 ; 29,10]	[23,50 ; 29,10]
$\mu_2 = e^{\mu+\alpha_2} e^{\sigma^2/2}$	18,10	0,99	[ 16,26 ; 20,16 ]	[16,24 ; 20,00 ]


- Deviance = 505,3,  $p_D = 55, 30$ ;  $DIC = 560, 6$ . Modelo sem efeito aleatório: Deviance = 654,8,  $p_D = 1, 8$ ;  $DIC = 656, 6$ .

# Posteriors das médias de cada grupo



# Valores observados e distribuições preditivas

Frequências observadas e preditas sob cada uma das priors



Frequências observadas e preditas sob cada uma das priors

