

# Inferência Bayesiana

## Conceitos Básicos e Algumas Aplicações

Prof. Fábio N. Demarqui

2012/01

## Background

- Breve histórico

- Problema fundamental da estatística

- Inferência Clássica ou frequentista

## Paradigma Bayesiano

- Probabilidade subjetiva

- Inferências via teorema de Bayes

## Distribuições *a priori*

- Priori Conjugadas

- Priori* impróprias

- Priori* flat

## Métodos MCMC

## Comparação de Modelos

- Modelo mais Provável a *posteriori*

- Fator de Bayes

- Deviance Information Criterion (DIC)

- Conditional Predictive Ordinate (CPO)

## Considerações finais

- ▶ Thomas Bayes (1702-1761) foi um matemático e pastor presbiteriano inglês.
- ▶ Em 1719 ingressou na Universidade de Edinburgh para estudar lógica e teologia.
- ▶ Mudou-se para Tunbridge Wells, Kent, por volta de 1734, onde permaneceu como ministro da Capela do Monte Sião até 1752.
- ▶ Thomas Bayes é conhecido por ter formulado o caso especial do teorema de Bayes (artigo publicado por um de seus pupilos após sua morte).
- ▶ Bayes foi eleito membro da Royal Society em 1742.



**Figura:** Thomas Bayes (1702-1761).

*"O problema fundamental da estatística é a inferência. Dados são coletados e a partir deles desejamos fazer declarações (inferências) sobre uma ou mais características desconhecidas do mecanismo (ou processo) que deu origem aos dados observados."*

- ▶ *A inferência estatística lida com o problema de tirar conclusões sobre quantidades não observadas a partir de dados numéricos (quantidades observadas).*
- ▶ *Tais quantidades não observadas podem ser de duas naturezas:*
  - ▶ *Quantidades que não são diretamente observáveis, tais como parâmetros que governam o processo hipotético que produz os dados observados;*
  - ▶ *Quantidades potencialmente observáveis, tais como observações futuras de um processo.*
- ▶ *As questões acima podem ser resolvidas utilizando-se tanto a inferência clássica (ou frequentista) quanto a inferência Bayesiana.*

## Exemplo

- ▶ *O fabricante de um tipo de isolador elétrico quer conhecer o comportamento de seu produto funcionando a uma temperatura de 200° C.*
- ▶ *60 isoladores foram colocados sob teste sob a condição desejada até que 45 deles falhassem (censura do tipo II).*
- ▶ *O fabricante está interessado em saber:*
  - ▶ *O tempo médio (MTTF) e mediano de vida do isolador.*
  - ▶ *O percentual de falhas após 500 horas de uso.*

- ▶ O tempo de vida dos isoladores elétricos está sujeito a variações aleatórias, isto é, não é possível prevermos com exatidão qual será o tempo de vida de um determinado componente eletrônico.
- ▶ É razoável assumirmos, entretanto, que exista algum processo gerador dos dados (tempos de vida), possivelmente governado por um conjunto de parâmetros.
- ▶ Tal processo pode ser representado por uma distribuição de probabilidades.
- ▶ Podemos, então aceitar os dados observados como a realização de uma variável aleatória  $Y$ , ou um conjunto de v.a.'s  $Y = (Y_1, \dots, Y_n)$ , com uma função de distribuição  $F_0$  que representa a variabilidade ou incerteza da observação de  $Y$ .

- ▶ Evidentemente, a função de distribuição  $F_0$  não é perfeitamente conhecida.
- ▶ No entanto, em geral, existe algum conhecimento inicial sobre a natureza do processo gerador dos dados que leva a propormos uma família de distribuições  $\mathcal{F}$  a que pertence  $F_0$ , e que chamaremos de modelo estatístico.
- ▶ Formalmente, definimos um modelo estatístico da seguinte forma

$$\mathcal{F} = \{f(y|\theta) : \theta \in \Theta\}, \quad y \in \mathcal{Y}, \quad (1)$$

em que  $\mathcal{Y}$  corresponde ao espaço amostral associado ao experimento e  $\Theta$  é chamado espaço paramétrico.

- ▶ Estamos interessados em encontrar o valor (fixo e desconhecido)  $\theta_0 \in \Theta$  que nos leva a  $F_0$ .



- ▶ A inferência clássica baseia-se no princípio da repetibilidade.
- ▶ Uma vez determinado o modelo estatístico, tanto a estimação de parâmetros quanto testes de hipóteses sobre os parâmetros são realizados levando-se em conta a variabilidade inerente à amostra observada.
- ▶ Em outras palavras, a idéia central da inferência clássica consiste em considerar-se a variabilidade que seria observada caso um mesmo experimento fosse repetido, sob as mesmas condições, um grande número de vezes.
- ▶ A teoria de verossimilhança desempenha papel de destaque na inferência clássica.

## Exemplo

- ▶ *Suponha que estamos interessados em saber qual a proporção atual (digamos  $\theta$ ) de mulheres na Europa.*
- ▶ *Evidentemente, além de muito demorado, seria economicamente inviável contar o número total de mulheres.*
- ▶ *Ao invés disso, podemos tentar tirar nossas conclusões com base em uma amostra de  $n$  pessoas escolhidas aleatoriamente da população em estudo.*
- ▶ *Seja  $X_i = 1$  se a  $i$ -ésima pessoa selecionada for uma mulher, e  $X_i = 0$  caso contrário.*
- ▶ *É natural assumirmos que  $X_1, \dots, X_n$  representa uma amostra aleatória de  $X \sim \text{Bernoulli}(\theta)$ , tal que*

$$P(X_i = 1) = \theta \quad \text{e} \quad P(X_i = 0) = 1 - \theta. \quad (2)$$

- ▶ Um candidato "natural" para  $\theta_0$  neste caso seria  $\hat{\theta} = \frac{1}{n} \sum_{i=1}^n X_i$ .
- ▶ Evidentemente, o valor de  $\hat{\theta}$  está sujeito a variações da amostra, isto é, diferentes amostras observadas levarão a diferentes valores de  $\hat{\theta}$ .
- ▶ Observe que  $\hat{\theta}$  é uma função das v.a.'s  $X_1, \dots, X_n$  ( $\hat{\theta}$  é de fato uma estatística), logo faz sentido estudarmos a sua distribuição de probabilidades.
- ▶ Em inferência clássica, conclusões acerca do parâmetro de interesse  $\theta_0$  são feitas com base na informação da amostra observada, considerando-se as possíveis variações dos valores observados quando da coleta de diferentes amostras.

- ▶ Defina  $Y = \sum_{i=1}^n X_i$ , então  $Y \sim Bin(n, \theta)$ . Então, nosso modelo estatístico assume a seguinte forma:

$$f(y|\theta) = \binom{n}{y} \theta^y (1 - \theta)^{n-y}, \quad y = 0, 1, 2, \dots, n. \quad (3)$$

- ▶ Note que, para qualquer valor  $\theta \in \Theta$ ,  $f(y|\theta)$  é uma probabilidade!
- ▶ Como escolher então um valor  $\hat{\theta} \in \Theta$  levando em conta apenas a informação de que dispomos, isto é, o valor observado  $y$ ?

- ▶ Defina  $Y = \sum_{i=1}^n X_i$ , então  $Y \sim Bin(n, \theta)$ . Então, nosso modelo estatístico assume a seguinte forma:

$$f(y|\theta) = \binom{n}{y} \theta^y (1 - \theta)^{n-y}, \quad y = 0, 1, 2, \dots, n. \quad (3)$$

- ▶ Note que, para qualquer valor  $\theta \in \Theta$ ,  $f(y|\theta)$  é uma probabilidade!
- ▶ Como escolher então um valor  $\hat{\theta} \in \Theta$  levando em conta apenas a informação de que dispomos, isto é, o valor observado  $y$ ?
- ▶ Basta tomarmos o valor de  $\theta$  que seja mais provável (verossímil) para a amostra observada!

- ▶ Matematicamente, o valor de  $\hat{\theta}$  mais provável dada a amostra observada é dado por

$$\hat{\theta} = \sup_{\theta \in \Theta} L(\theta|y) = f(y|\theta). \quad (4)$$

- ▶ A função  $L(\theta|y) = f(y|\theta)$  é chamada função de verossimilhança.
- ▶ Condicional nos dados observados,  $L(\theta|y)$  deve ser vista como uma função de  $\theta$ .
- ▶ Observe que é através de  $L(\theta|y)$  que a informação dos dados observados é utilizada no processo inferencial.
- ▶ Pode ser mostrado que o valor  $\hat{\theta}$  que maximiza  $L(\theta|y)$  é  $\hat{\theta} = \frac{1}{n} \sum_{i=1}^n X_i$ .
- ▶ Dizemos então que  $\hat{\theta} = \frac{1}{n} \sum_{i=1}^n X_i$  é o estimador de máxima verossimilhança de  $\theta$ .

## Exemplo

*Vejamos um exemplo numérico...*

- ▶ A inferência Bayesiana adota uma postura subjetivista através do uso explícito de probabilidades para quantificar o grau de incerteza acerca de quantidades de interesse não observadas.
- ▶ O objetivo da inferência Bayesiana consiste em combinar toda a informação subjetiva disponível referente a um problema, com a informação proveniente dos dados observados, através de declarações probabilísticas via teorema de Bayes.
- ▶ Etapas da análise Bayesiana:
  1. Especificação de um modelo probabilístico "completo": distribuição conjunta para todas as quantidades observadas e não observadas do problema em questão.
  2. Obtenção da distribuição a *posteriori*: distribuição condicional das quantidades não observadas dado os dados observados.
  3. Verificação da adequação do modelo ajustado aos dados.



- ▶ O que vem a ser uma probabilidade subjetiva?

- ▶ O que vem a ser uma probabilidade subjetiva?
- ▶ Qual time sairá vencedor no próximo confronto entre Cruzeiro e Atlético?

- ▶ O que vem a ser uma probabilidade subjetiva?
- ▶ Qual time sairá vencedor no próximo confronto entre Cruzeiro e Atlético?
- ▶ Obviamente, cruzeirenses e atleticanos têm opiniões bastante distintas quanto ao time que sairá vitorioso.

- ▶ O que vem a ser uma probabilidade subjetiva?
- ▶ Qual time sairá vencedor no próximo confronto entre Cruzeiro e Atlético?
- ▶ Obviamente, cruzeirenses e atleticanos têm opiniões bastante distintas quanto ao time que sairá vitorioso.
- ▶ Informalmente, podemos definir a probabilidade subjetiva como a crença que o observador do experimento possui na ocorrência do evento de interesse.

- ▶ O que vem a ser uma probabilidade subjetiva?
- ▶ Qual time sairá vencedor no próximo confronto entre Cruzeiro e Atlético?
- ▶ Obviamente, cruzeirenses e atleticanos têm opiniões bastante distintas quanto ao time que sairá vitorioso.
- ▶ Informalmente, podemos definir a probabilidade subjetiva como a crença que o observador do experimento possui na ocorrência do evento de interesse.
- ▶ Voltando à próxima partida entre Atlético e Cruzeiro, as chances de vitória que um torcedor atribui ao seu time do coração podem ser interpretadas como probabilidades subjetivas.

- ▶ O que vem a ser uma probabilidade subjetiva?
- ▶ Qual time sairá vencedor no próximo confronto entre Cruzeiro e Atlético?
- ▶ Obviamente, cruzeirenses e atleticanos têm opiniões bastante distintas quanto ao time que sairá vitorioso.
- ▶ Informalmente, podemos definir a probabilidade subjetiva como a crença que o observador do experimento possui na ocorrência do evento de interesse.
- ▶ Voltando à próxima partida entre Atlético e Cruzeiro, as chances de vitória que um torcedor atribui ao seu time do coração podem ser interpretadas como probabilidades subjetivas.
- ▶ Evidentemente, a probabilidade subjetiva deve ser coerente no sentido de satisfazer os axiomas de probabilidade...

- ▶ Suponha que tenhamos interesse em estimar um parâmetro  $\theta$ , para o qual dispomos de alguma informação *a priori* que julgamos ser relevante.
- ▶ Tal informação pode ser representada probabilisticamente através da chamada distribuição *a priori* de  $\theta$ , que denotaremos por  $\pi(\theta)$ .
- ▶ Assim como na abordagem frequentista, toda a informação proveniente dos dados observados é carregada pela função de verossimilhança  $L(\theta|y) = f(y|\theta)$ .
- ▶ A informação contida em  $\pi(\theta)$  é, então, atualizada através da informação dos dados contida em  $L(\theta|y) = f(y|\theta)$ , via teorema de Bayes, levando à distribuição *a posteriori* de  $\theta$ , dada por

$$\pi(\theta|y) = \frac{L(\theta|y)\pi(\theta)}{\int_{\Theta} L(\theta|y)\pi(\theta)d\theta}. \quad (5)$$

- ▶ A distribuição *a posteriori* de  $\theta$  contém toda a informação de que dispomos para fazermos inferências sobre  $\theta$ .
- ▶ É a partir dela que todas as estatísticas necessárias para descrevermos o comportamento de  $\theta$  são extraídas.
- ▶ Assim, de posse da distribuição *a posteriori* de  $\theta$ , podemos encontrar, por exemplo, o percentil de ordem  $100(1 - \alpha)\%$  de  $\theta$ ,

$$P_\alpha = \left\{ \theta' \in \Theta : \int_{-\infty}^{\theta'} \pi(\theta|y) d\theta \right\} = \alpha, \quad 0 < \alpha < 1. \quad (6)$$



- ▶ Estimativas pontuais para  $\theta$  podem ser obtidas a partir de alguma medida de centralidade associada a distribuição *a posteriori* de  $\theta$ . Três escolhas comuns são:

- ▶ Média *a posteriori*,

$$\hat{\theta} = E(\theta|y) = \int_{\Theta} \theta \pi(\theta|y) d\theta;$$

- ▶ Mediana *a posteriori*,

$$\hat{\theta} = P_{0.5};$$

- ▶ Moda *a posteriori*,

$$\hat{\theta} : \pi(\hat{\theta}|y) = \sup_{\theta} \pi(\theta|y).$$

- ▶ A quantidade

$$f(y) = \int_{\Theta} L(\theta|y)\pi(\theta)d\theta;$$

é chamada distribuição preditiva a *priori* de  $y$ .

- ▶ Predições podem ser feitas através da distribuição preditiva a *posteriori* de  $y$ ,

$$f(\tilde{y}) = \int_{\Theta} f(\tilde{y}|\theta)\pi(\theta|y)d\theta;$$

- ▶ A distribuição *a posteriori* de  $\theta$  também nos permite fazer declarações probabilísticas sobre  $\theta$ . Por exemplo, podemos encontrar  $\theta'$  e  $\theta''$  a partir da solução de

$$\theta' = \int_{-\infty}^{\theta'} \pi(\theta|y)d\theta = \alpha/2 \text{ e } \theta'' = \int_{\theta''}^{\infty} \pi(\theta|y)d\theta = \alpha/2, \quad (7)$$

tal que  $P(\theta' < \theta < \theta'') = 1 - \alpha$ .

- ▶ Desta forma, o conjunto  $(\theta', \theta'')$  representa um intervalo de credibilidade de  $100(1 - \alpha)\%$  para  $\theta$ .
- ▶ Alternativamente, podemos ainda obter o chamado intervalo HPD (highest posterior density), que corresponde à região  $\Theta' \subset \Theta$  de mais alta densidade de  $\pi(\theta|y)$ .

- ▶ Na escolha por uma família de distribuições *a priori* são desejáveis as propriedades:
  - ▶ Versatilidade para acomodar o maior número possível de crenças *a priori*.
  - ▶ Interpretabilidade para facilitar o processo de sumariação dos seus membros.
  - ▶ Simplicidade da derivação analítica das distribuições *a posteriori* e preditivas.
- ▶ Na prática tais propriedades desejáveis estão, em geral, em dessintonia.
- ▶ A simplicidade da operação Bayesiana poderá ficar garantida se impusermos algumas restrições sobre a família de distribuições *a priori* de  $\theta$ , como veremos nos exemplos a seguir.

## Exemplo

Retornando ao exemplo da proporção de mulheres na Europa, suponha que uma amostra de tamanho  $n$  foi coletada. Temos

- ▶ Função de verossimilhança

$$L(\theta|y) = \binom{n}{y} \theta^y (1 - \theta)^{n-y}, \quad (8)$$

- ▶ Distribuição *a priori*:

$$\pi(\theta) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \theta^{\alpha-1} (1 - \theta)^{\beta-1}, \quad 0 < \theta < 1 \quad (9)$$

que corresponde uma distribuição beta com parâmetros  $\alpha > 0$  e  $\beta > 0$ , (denotaremos  $\theta \sim \text{Beta}(\alpha; \beta)$ ).


- ▶ Se  $\theta \sim \text{Beta}(\alpha; \beta)$ , então

$$E(\theta) = \frac{\alpha}{\alpha + \beta}. \quad (10)$$

$$\text{moda}(\theta) = \frac{\alpha - 1}{\alpha + \beta - 2} \quad (11)$$

$$\text{VAR}(\theta) = \frac{\alpha\beta}{(\alpha + \beta + 1)(\alpha + \beta)^2} \quad (12)$$

- ▶ A distribuição beta é uma distribuição bastante rica em formas...



**Figura:** Distribuição  $Beta(\alpha; \beta)$  segundo diferentes escolhas de  $\alpha$  e  $\beta$ .

- ▶ Modelo probabilístico completo:

$$\begin{aligned}\pi(y, \theta) &= L(\theta|y)\pi(\theta) \\ &= \binom{n}{y} \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \theta^{\alpha+y-1} (1 - \theta)^{\beta+n-y-1} \quad (13)\end{aligned}$$

- ▶ Distribuição preditiva *a priori*:

$$\begin{aligned}f(y) &= \int_0^1 f(y|\theta)\pi(\theta)d\theta \\ &= \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \frac{\Gamma(\alpha + n)\Gamma(\beta + n - y)}{\Gamma(\alpha + \beta + n)}. \quad (14)\end{aligned}$$



- ▶ Distribuição *a posteriori*:

$$\pi(\theta|y) = \frac{\Gamma(\alpha_* + \beta_*)}{\Gamma(\alpha_*)\Gamma(\beta_*)} \theta^{\alpha_*-1} (1 - \theta)^{\beta_*-1} \quad (15)$$

em que  $\alpha_* = \alpha + y$  e  $\beta_* = \beta + n - y$ .

- ▶ Note que  $\pi(\theta|y)$  pertence à mesma família de distribuições (família Beta) da distribuição  $\pi(\theta)$ .
- ▶ Dizemos então que a família de distribuições Beta é a família conjugada natural da família de distribuições Binomial (modelo estatístico assumido neste exemplo).
- ▶ De fato, a família de distribuições Beta corresponde à família conjugada natural das famílias de distribuições Bernoulli, Binomial e Geométrica.

- ▶ Voltando ao nosso exemplo, a título de ilustração, vamos consideradas as seguintes distribuições *priori* para  $\theta$ :

Tabela: Distribuições *a priori* de  $\theta$ .

$\pi(\theta)$	$E(\theta)$	$moda(\theta)$	$VAR(\theta)$
$Beta(1, 1)$	0.5	0.5	0.0883
$Beta(10, 10)$	0.5	0.5	0.0119
$Beta(1, 10)$	0.0909	-	0.0069

- ▶ Graficamente, temos...




Figura: Distribuição *a priori* de  $\theta$ .

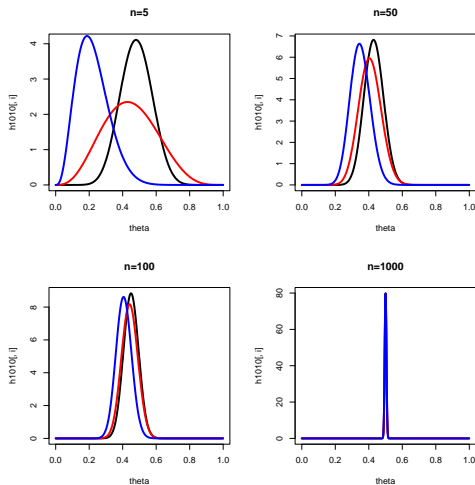


Figura: Distribuição *a posteriori* de  $\theta$ .

## Exemplo

- ▶ *Vamos retornar agora ao exemplo do tempo de vida dos isoladores elétricos.*
- ▶ *Suponha que temos motivos para acreditar que a distribuição exponencial*

$$f(y|\theta) = \theta e^{-\theta y}, \quad \theta > 0, \quad (16)$$

*corresponde a um modelo estatístico adequado para o problema.*

- ▶ *A família Gama de distribuições corresponde a família conjugada natural da distribuição exponencial.*
- ▶ *Assim, assumiremos que*

$$\pi(\theta) = \frac{\gamma_0^{\alpha_0}}{\Gamma(\alpha_0)} \theta^{\alpha_0-1} e^{-\gamma_0 \theta}, \quad \alpha_0 > 0, \gamma_0 > 0. \quad (17)$$

- ▶ Se  $\theta \sim \text{Gama}(\alpha_0, \gamma_0)$ , então:

$$E(\theta) = \frac{\alpha_0}{\gamma_0} \quad (18)$$

e

$$V(\theta) = \frac{\alpha_0}{\gamma_0^2}. \quad (19)$$

- ▶ É fácil mostrar que  $\alpha_0 = \frac{E(\theta)^2}{V(\theta)}$  e  $\gamma_0 = \frac{E(\theta)}{V(\theta)}$ .
- ▶ Logo, se a informação subjetiva disponível puder ser expressada em termos de  $E(\theta)$  e  $V(\theta)$ , é possível especificarmos os valores de  $\alpha_0$  e  $\gamma_0$  de modo a refletir nosso conhecimento *a priori* sobre o problema.

- Função de verossimilhança:

$$L(\theta|y) = f(y_1, \dots, y_n|\theta) = \theta^{\sum_{i=1}^n \delta_i} \exp \left\{ -\theta \sum_{i=1}^n y_i \right\} \quad (20)$$

em que  $y = (y_1, \dots, y_n)$ .

- Modelo probabilístico completo:

$$\begin{aligned} \pi(y, \theta) &\propto L(\theta|y)\pi(\theta) \\ &\propto \theta^{\alpha_0 + \sum_{i=1}^n \delta_i - 1} \exp \left\{ -\theta \left[ \gamma_0 + \sum_{i=1}^n y_i \right] \right\}, \end{aligned} \quad (21)$$

que corresponde ao núcleo da distribuição gama, isto é,

$$(\theta|y) \sim \text{Gama}(\alpha; \gamma),$$

em que  $\alpha = \alpha_0 + \sum_{i=1}^n \delta_i$  e  $\gamma = \gamma_0 + \sum_{i=1}^n y_i$ .

- Distribuição preditiva *a priori*:

$$\begin{aligned} f(y) &= \int_0^{\infty} f(y|\theta)\pi(\theta)d\theta \\ &= \frac{\gamma_0^{\alpha_0}}{\Gamma(\alpha_0)} \frac{\Gamma(\alpha_0 + \sum_{i=1}^n \delta_i)}{[\gamma_0 + \sum_{i=1}^n y_i]^{(\alpha_0 + n \sum_{i=1}^n \delta_i)}}. \end{aligned} \quad (22)$$

- Distribuição preditiva *a posteriori*:

$$\begin{aligned} f(y_{n+1}|y) &= \int_0^{\infty} f(y_{n+1}|\theta)\pi(\theta|y)d\theta \\ &= \frac{\gamma^{\alpha}}{\Gamma(\alpha)} \frac{\Gamma(\alpha + 1)}{[\gamma + y_{n+1}]^{(\alpha+1)}}. \end{aligned} \quad (23)$$

- Função de confiabilidade *a posteriori*:

$$\begin{aligned} R(t|y) + P(Y_{n+1} > t|y) &= \int_0^{\infty} e^{-\theta t} \pi(\theta|y) d\theta \\ &= \left( \frac{\gamma}{\gamma + t} \right)^{(\alpha)} \end{aligned} \quad (24)$$



- ▶ Dizemos que uma *priori*  $\pi(\theta)$  é imprópria se

$$\int_{\Theta} \pi(\theta) d\theta = \infty. \quad (25)$$

- ▶ *Priori* impróprias são frequentemente utilizadas em inferência Bayesiana  $\rightarrow$  *priori* **não informativas**.
- ▶ Observações:
  - ▶ *Priori* impróprias podem levar a *posteriori* impróprias.
  - ▶ Não podemos fazer inferências com base em uma *posteriori* imprópria.
  - ▶ Para verificarmos se uma *posteriori* é própria, basta mostrarmos que

$$\int_{\Theta} f(y|\theta)\pi(\theta) d\theta < \infty, \quad (26)$$

o que nem sempre é uma tarefa fácil.

- ▶ Se  $\pi(\theta)$  é própria, então  $\pi(\theta|y)$  também é própria! (Por que???)

- ▶ Seja  $f(y|\theta)$ . Então a matriz de informação de Fisher esperada é dada por

$$I(\theta) = E \left[ -\frac{\partial^2}{\partial \theta^2} \log f(y|\theta) \right] \quad (27)$$

- ▶ A *priori* de Jeffreys é definida da seguinte forma

$$\pi(\theta) \propto |I(\theta)|^{1/2}, \quad (28)$$

- ▶ A *priori* de Jeffreys é invariante com respeito a transformações.
- ▶ Seja  $\phi = h(\theta)$ . Então,

$$\pi(\phi) = \pi(\theta) \left\| \frac{d\theta}{d\phi} \right\|, \quad (29)$$

em que  $\theta = h^{-1}(\phi)$

- ▶ Dizemos que uma *priori*  $\pi(\theta)$  é flat (ou vaga) se

$$V(\theta) \rightarrow \infty \quad (30)$$

- ▶ *Priori* flat são bastante utilizadas quando temos interesse em usar uma *priori* que seja não informativa.
- ▶ Observações:
  - ▶ A *posteriori* resultante é sempre própria.
  - ▶ Os softwares WinBUGS e OpenBUGS não aceitam *priori* impróprias.

- ▶ Em geral, uma expressão fechada para a distribuição *a posteriori*

$$\pi(\theta|y) = \frac{L(\theta|y)\pi(\theta)}{\int_{\Theta} L(\theta|y)\pi(\theta)d\theta} \quad (31)$$

não pode ser obtida, pois a integral que aparece no denominador em (31) não possui solução analítica.

- ▶ Em situações como esta, a distribuição *a posteriori* pode ser obtida através de métodos numéricos.
- ▶ Neste cenário, métodos de simulação via Monte Carlo via Cadeias de Markov (MCMC) tem sido amplamente utilizados, com destaque para:
  - ▶ Amostrador de Gibbs (Gibbs Sampler);
  - ▶ Algoritmo de Metropolis-Hastings;

- ▶ Para a implementação de métodos MCMC precisamos conhecer apenas o núcleo da distribuição a *posteriori* de  $\theta$ , isto é,

$$\pi(\theta|y) \propto L(\theta|y)\pi(\theta). \quad (32)$$

- ▶ A idéia básica é que se conhecemos o núcleo de  $\pi(\theta|y)$ , então é possível gerarmos amostras dessa distribuição usando teoria de cadeias de Markov.
- ▶ Com uma amostra da distribuição a *posteriori* de  $\theta$ , características de  $\pi(\theta|y)$  podem ser estudadas empiricamente através de técnicas descritivas.

- ▶ Um dos métodos mais comuns de seleção de modelos se dá através da comparação das probabilidades a *posteriori* dos modelos sob investigação.
- ▶ Seja  $m$  um modelo pertencente aos espaço de modelos  $\mathcal{M}$ .
- ▶ A probabilidade a *posteriori* do modelo  $m$  é dada por

$$\pi(m|y) = \frac{\pi(D|m)\pi(m)}{\sum_{m \in \mathcal{M}} \pi(D|m)\pi(m)}, \quad (33)$$

em que

$$\pi(D|m) = \int L(\theta^m|y)\pi(\theta^m)d\theta^m, \quad (34)$$

e  $\pi(m)$  denota a probabilidade a *priori* do modelo  $m$ .

- ▶ Sejam  $\mathcal{M}_1$  e  $\mathcal{M}_2$  dois modelos a serem comparados.
- ▶ O Fator de Bayes (BF) é definido como

$$\begin{aligned}BF(\mathcal{M}_1, \mathcal{M}_2) &= \frac{\pi(\mathcal{M}_1|y)/\pi(\mathcal{M}_2|y)}{\pi(\mathcal{M}_1)/\pi(\mathcal{M}_2)} \\ &= \frac{\pi(y|\mathcal{M}_1)}{\pi(y|\mathcal{M}_2)},\end{aligned}\tag{35}$$

em que

$$\pi(y|\mathcal{M}_k) = \int L(\theta_k|y)\pi(\theta_k)d\theta_k,\tag{36}$$

$k = 1, 2$ .

- ▶ Evidentemente, o modelo com maior probabilidade a *posteriori* é preferível.

- ▶ Escala de evidência em favor de  $\mathcal{M}_1$  proposta por Kass & Raftery (1995):

**Tabela:** Escala de evidência em favor de  $\mathcal{M}_1$

1-3	não significativa
3-30	positiva
30-150	forte
> 150	mutio forte



- ▶ A deviance é definida da seguinte forma

$$D(y, \theta) = -2 \log f(y|\theta). \quad (37)$$

- ▶ O DIC é definido como

$$DIC = 2\hat{D}_{avg}(y) - D_{\hat{\theta}}(y) \quad (38)$$

em que

$$\hat{D}_{avg}(y) = \frac{1}{N} \sum_{l=1}^N D(y, \theta^l) \quad (39)$$

e

$$D_{\hat{\theta}}(y) = D(y, \hat{\theta}). \quad (40)$$

- ▶ A quantidade

$$p_D = \hat{D}_{avg}(y) - D_{\hat{\theta}}(y) \quad (41)$$

é frequentemente utilizada como uma medida do número efetivo de parâmetros no modelo Bayesiano.

- ▶ Modelos que apresentam DIC com menor valor são preferíveis.
- ▶ Problemas:
  - i)  $p_D$  pode ser negativo em alguns casos.
  - ii) não é recomendado para modelos com vários níveis de hierarquia.

- ▶ A quantidade

$$CPO_i = f(y_i|y_{-i}) = \int f(y_i|\theta)\pi(\theta|y_{-i})d\theta \quad (42)$$

é chamada conditional predictive ordinate.

- ▶ Uma medida bastante utilizada para a comparação de modelos em inferência Bayesiana é

$$LPML = \sum_{i=1}^n \log(CPO_i). \quad (43)$$

- ▶ Modelos com maior valor de LPML são preferíveis.
- ▶ Pode ser mostrado que

$$\widehat{CPO}_i \approx M \left\{ \sum_{l=1}^M [f(y_i|\theta^l)]^{-1} \right\}^{-1}, \quad l = 1, \dots, M. \quad (44)$$

## Inferência Clássica:

- baseia-se no princípio da repetibilidade;
- o conceito de aleatoriedade está associado a variabilidade verificada através da coleta de diferentes amostras;
- em geral, depende de resultados assintóticos.

## Inferência Bayesiana:

- postura subjetivista;
- uso explícito da probabilidade para quantificar a incerteza;
- atribui-se probabilidades aos possíveis valores que o(s) parâmetro(s) pode(m) assumir;
- não depende de resultados assintóticos.
- opiniões subjetivas coerentes  $\Rightarrow$  axiomas de probabilidade são satisfeitos.

## Vantagens:

- ▶ Permite a inclusão de informação subjetiva relevante durante o processo inferencial.
- ▶ Fornece maior flexibilidade na modelagem dos dados, especialmente para conjuntos de dados com estruturas mais complexas.

## Desvantagens:

- ▶ Salvo algumas situações envolvento problemas relativamente simples, exige um custo computacional alto.
- ▶ A implementação de métodos MCMC pode não ser trivial, requerendo certo grau de experiência por parte do analista.