

## Análise de verossimilhança bayesiana

- Agora vamos ver o modo bayesiano de ajuste de modelos. O teorema de Bayes diz que:

$$\text{prob}(\vec{\alpha}|X_i) \propto \mathcal{L}(X_i|\vec{\alpha})\text{prob}(\vec{\alpha})$$

de modo que, claramente, a verossimilhança continua sendo muito importante.

- A principal diferença do método da máxima verossimilhança, além do fator *a priori* é que o resultado, o posterior, é uma função que tem os parâmetros  $\vec{\alpha}$  como variáveis, não apenas o valor mais provável e sua incerteza.
- As duas maiores vantagens do método bayesiano são a possibilidade de lidar com parâmetros indesejáveis via marginalização e o uso da *evidência* ou *fator da Bayes* para escolher entre modelos.

## Análise de verossimilhança bayesiana

- Um outro produto útil do modo bayesiano é a distribuição assintótica da função de verossimilhança. Esta é uma gaussiana multivariada centrada nas MLE  $\hat{\vec{\alpha}}$ . Sua matriz de covariância é a inversa da matriz de informação de Fisher:

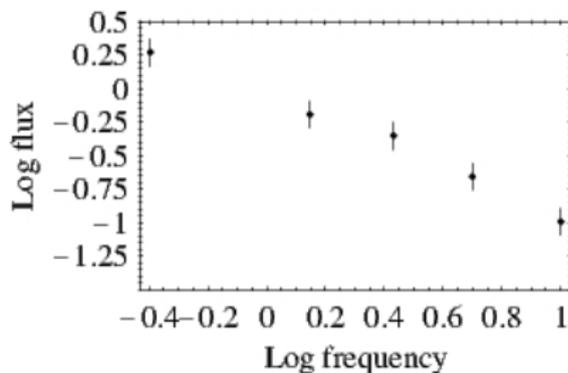
$$F = - \begin{bmatrix} \frac{\partial^2 \ln \mathcal{L}}{\partial \alpha_1^2} & \frac{\partial^2 \ln \mathcal{L}}{\partial \alpha_1 \partial \alpha_2} & \frac{\partial^2 \ln \mathcal{L}}{\partial \alpha_1 \partial \alpha_3} & \cdots \\ \frac{\partial^2 \ln \mathcal{L}}{\partial \alpha_2 \partial \alpha_1} & \frac{\partial^2 \ln \mathcal{L}}{\partial \alpha_2^2} & \frac{\partial^2 \ln \mathcal{L}}{\partial \alpha_2 \partial \alpha_3} & \cdots \\ \frac{\partial^2 \ln \mathcal{L}}{\partial \alpha_3 \partial \alpha_1} & \frac{\partial^2 \ln \mathcal{L}}{\partial \alpha_3 \partial \alpha_2} & \frac{\partial^2 \ln \mathcal{L}}{\partial \alpha_3^2} & \cdots \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \end{bmatrix}_{\vec{\alpha} = \hat{\vec{\alpha}}}$$

- A verossimilhança então é:

$$\mathcal{L}(\vec{\alpha} | X_i) = \mathcal{L}(\hat{\vec{\alpha}} | X_i) \exp \left[ -\frac{1}{2} (\vec{\alpha} - \hat{\vec{\alpha}})^T F (\vec{\alpha} - \hat{\vec{\alpha}}) \right],$$

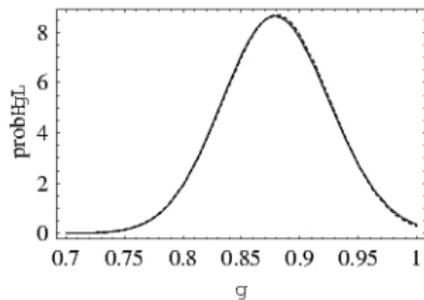
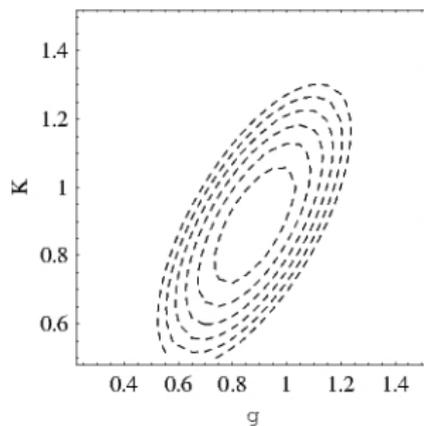
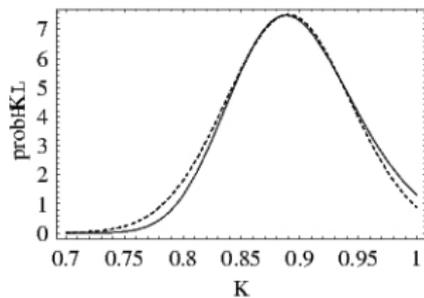
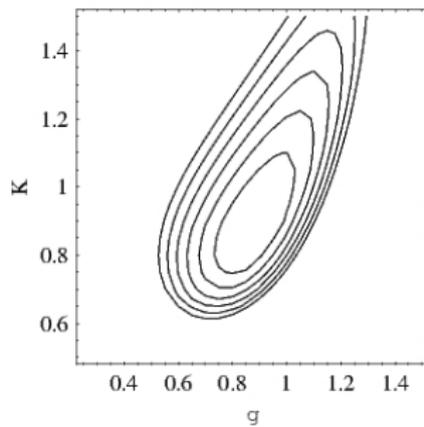
onde  $T$  denota matriz transposta. Essa é a chamada aproximação de Laplace.

## Exemplo W&J P. 143



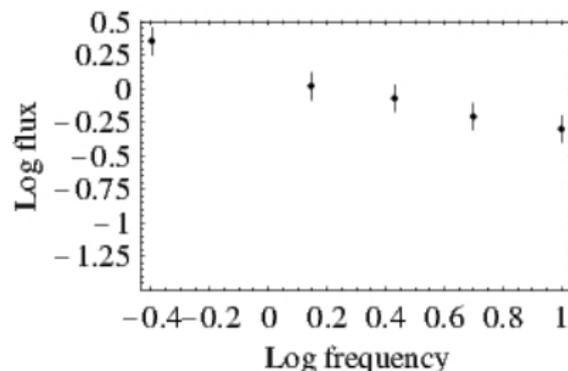
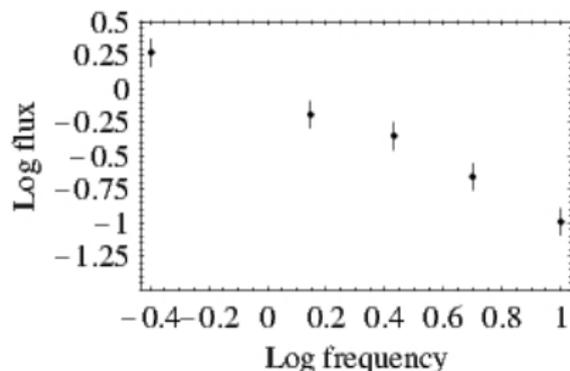
$$S = Kf^{-\gamma}$$

$$\mathcal{L} = \prod_{i=1}^5 \frac{1}{\sqrt{2\pi\epsilon Kf_i^{-\gamma}}} \exp \left[ -\frac{(S_i - Kf_i^{-\gamma})^2}{2(\epsilon Kf_i^{-\gamma})^2} \right]$$



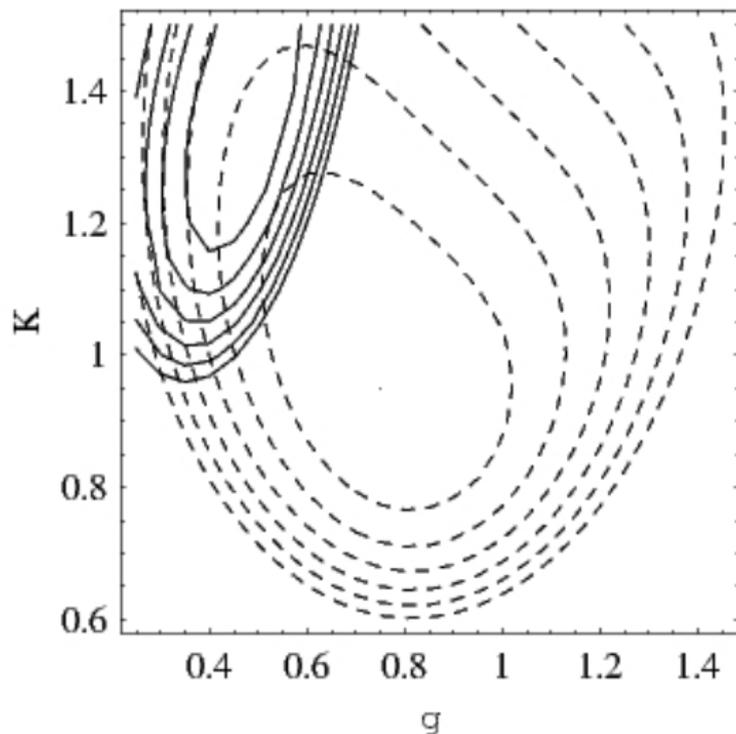
# Análise de verossimilhança bayesiana

Exemplo W&J P. 145



$$\mathcal{L} = \prod_{i=1}^5 \frac{1}{\sqrt{2\pi\epsilon}Kf_i^{-\gamma}} \exp \left[ -\frac{[S_i - (\beta + Kf_i^{-\gamma})]^2}{2(\epsilon Kf_i^{-\gamma})^2} \right]$$

$$\text{prob}(\beta) = \frac{1}{\sqrt{2\pi\epsilon}} \exp \left[ -\frac{(\beta - 0.4)^2}{2\epsilon^2} \right]$$



# MCMC: Markov Chain Monte Carlo

- Amostrar uma distribuição de probabilidades arbitrária
- Eficiente para amostrar distribuições complexas
- Computacionalmente intensivo

# MCMC: Markov Chain Monte Carlo

- Objetivo do MCMC: gerar uma sequência de pontos no espaço de parâmetros cuja distribuição é  $P(x)$
- Processo de Markov: a próxima amostra depende da atual mas não das anteriores
- A geração de novas amostras deve obedecer o princípio do “balanceamento detalhado”: a probabilidade de se ir de um ponto  $x_1$  no espaço de parâmetros a um ponto  $x_2$  é igual à probabilidade de se ir de  $x_2$  a  $x_1$

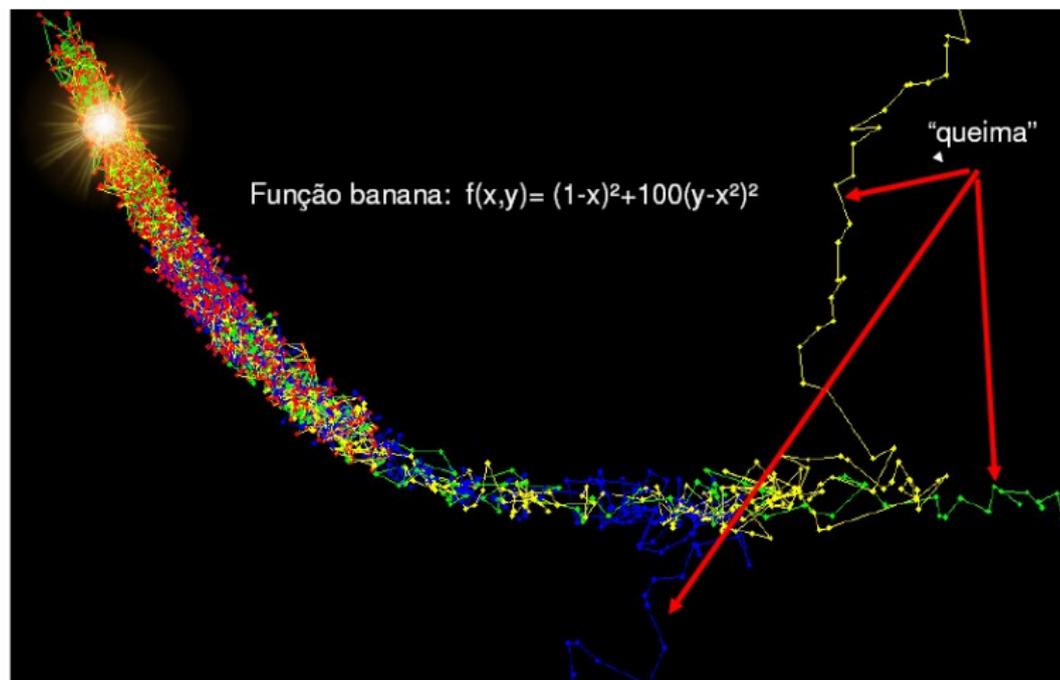
- O algoritmo de Metropolis:

- ▶ Comece num ponto  $x_1$  e determine um novo ponto  $x_2$ :

$$x_2 = x_1 + \epsilon$$

- ▶ O valor de  $\epsilon$  deve ser sorteado, via o método de Monte Carlo, com uma distribuição que é usualmente gaussiana - *random walk*.
- ▶ Se  $P(x_2) > P(x_1)$  aceita o novo ponto
- ▶ Se  $P(x_2) < P(x_1)$  aceita com probabilidade  $P(x_2)/P(x_1)$  (Via Monte Carlo)
- ▶ Se um novo ponto é aceito, faz-se  $x_1 \leftarrow x_2$
- ▶ Determina-se um novo  $x_2$  e repete-se o processo

# MCMC: Markov Chain Monte Carlo



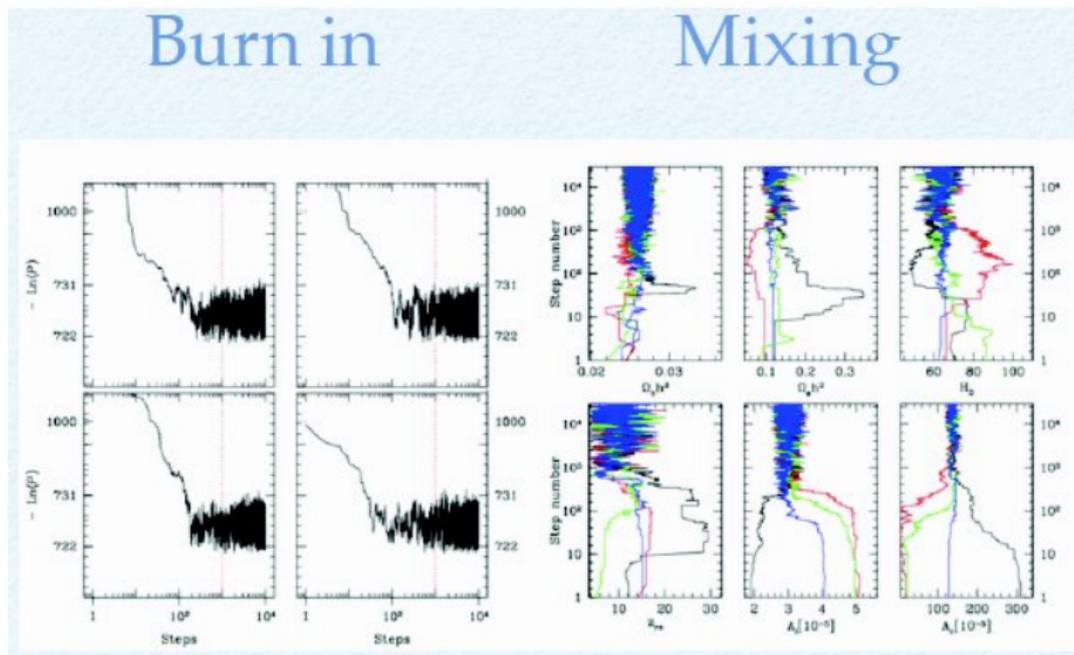
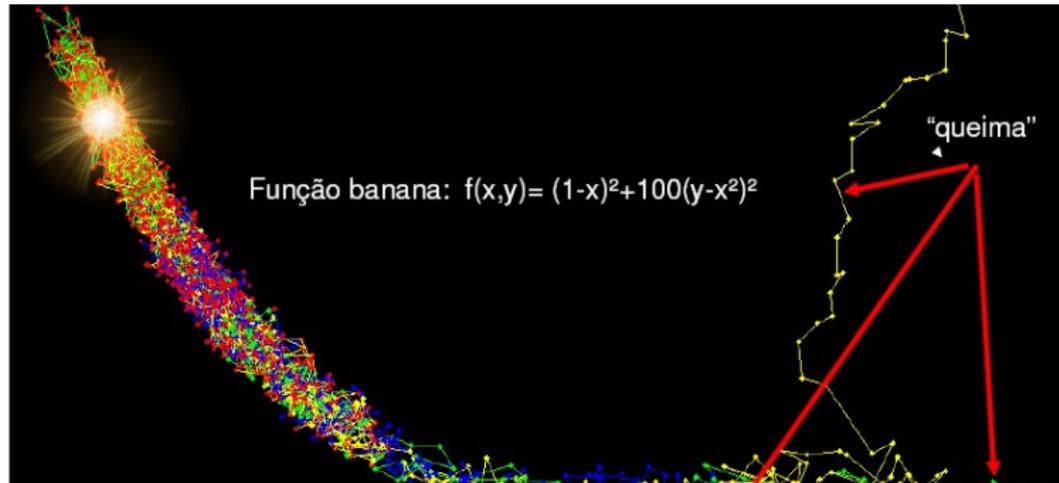


Figure : Diagnóstico de MCMC.

# MCMC: Markov Chain Monte Carlo

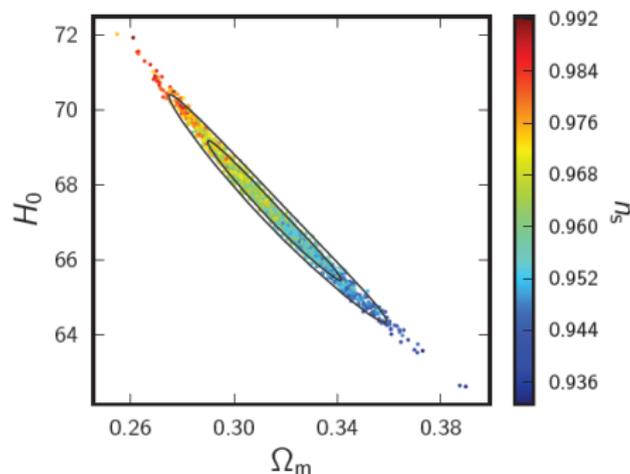
- Na prática:

- ▶ Trabalha-se com várias cadeias ( $>4$ )
- ▶ Desprezam-se as primeiras amostras de cada cadeia (“queima”)
- ▶ Aplicam-se testes para verificar se as cadeias convergiram
- ▶ Verifica-se a taxa de aceitação de pontos. Valores entre 15% e 50% são considerados saudáveis.



# MCMC: Markov Chain Monte Carlo

- Obtendo-se amostras do posterior via MCMC pode-se resumir a inferência via:
  - ▶ Melhor solução: média, mediana, moda
  - ▶ Regiões de confiança (“erros”)



## Bootstrap e jacknife: bootstrap

- Bootstrap e jacknife são técnicas para estimar incertezas nos parâmetros obtidos nos modelos.
- Bootstrap: Dada uma amostra com  $N$  pontos:
  - 1 “Rotule cada ponto”
  - 2 Gere uma nova amostra com  $N$  pontos tomados aleatoriamente da amostra original
  - 3 Recalcule os parâmetros com a nova amostra
  - 4 Repita a operação o máximo número de vezes possível.
- A distribuição dos parâmetros gerados por esse procedimento é uma excelente aproximação para as incertezas envolvidas no processo.

## Bootstrap e jacknife: jacknife

- Jacknife: Suponha que estamos interessados numa função  $f(X_1, X_2, \dots, X_N)$  que é um bom estimador de uma parâmetro  $\alpha$ :

$$\hat{\alpha} = f(X_1, X_2, \dots, X_N)$$

- A  $j$ -ésima estimativa parcial é obtida removendo-se o  $j$ -ésimo elemento no conjunto de dados:

$$\hat{\alpha} = f(X_1, X_2, \dots, X_{j-1}, X_{j+1}, \dots, X_N)$$

o que nos dá  $N$  estimativas parciais.

- O próximo (e crucial) passo é definir os pseudo valores:

$$\hat{\alpha}_j^* = N\hat{\alpha} - (N-1)\hat{\alpha}_j$$

- Finalmente o estimativa via *jackknife* de  $\alpha$  será a média dos pseudo valores

$$\hat{\alpha}^* = \frac{1}{N} \sum_{j=1}^N \hat{\alpha}_j^*$$

## Bootstrap e jacknife: jacknife

- Bootstrap e jacknife são os exemplos mais comuns de técnicas de validação (*cross-validation*) nas quais o conjunto de dados é dividido em partes e os resultados da análise das partes são comparados por consistência. Há uma série de variantes sofisticadas dessa ideia.