

# O Método MCMC, Aplicações e uma Visão Crítica




Tiago Castro, Miguel Quartin

- MCMC
  - Propriedades do Algoritmo de Metropolis
  - Altos e Baixos
- Testes de Convergência
  - Gelman-Rubin (Cadeias Paralelas)
  - Espectro de Potência
- Otimização do Método
  - Usando diferentes funções de teste
- Conclusões

# Algoritmo de Metropolis



- A densidade de pontos (espaço de parâmetros) na cadeia é proporcional à distribuição alvo
- Marginalização é feita somente por contagens
- Parte da cadeia (burn in) não representa a distribuição alvo fidedignamente

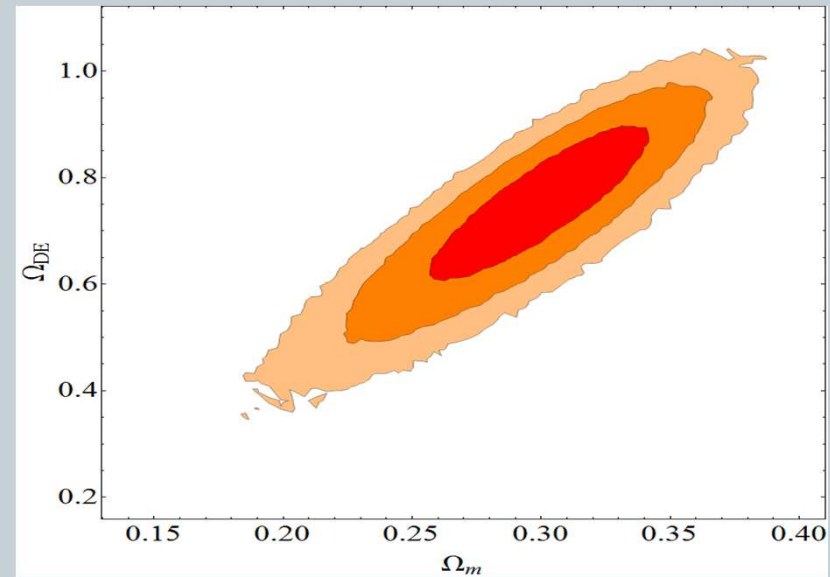



**!! $x_0$  deve ser escolhido na região de alta probabilidade da Likelihood, ou devemos descartar a fase de burn in!!**

# Altos e Baixos


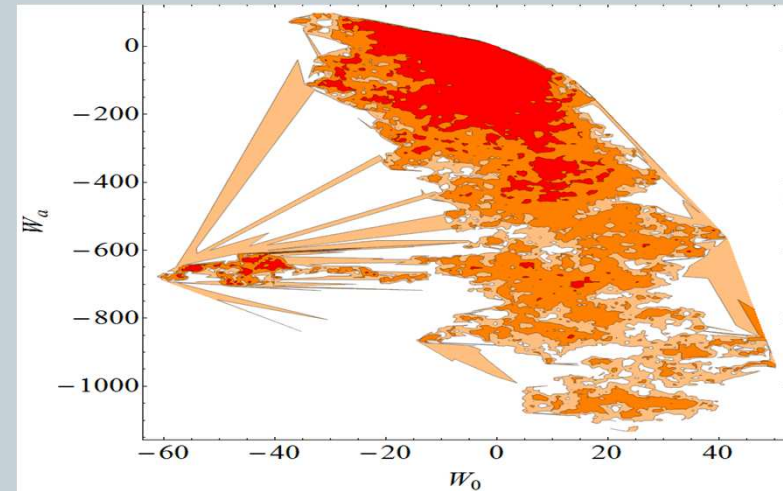



- Tempo necessário escala linearmente com D  
(Na grid é exponencialmente)
- Marginalização Trivial



Contornos para LCDM e  
marginalização sobre  $\Omega_{DE}$

## Altos e Baixos (2)



Concordância entre GRID e MCMC  
para  $\Lambda$ CDM e problemas com não  
Gaussianidades acentuadas  
CPL chato(10x o  $\Lambda$ CDM) e oCPL(40x)

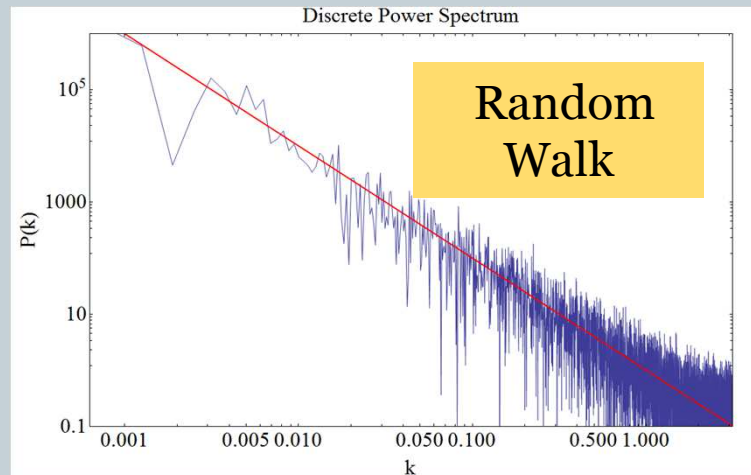

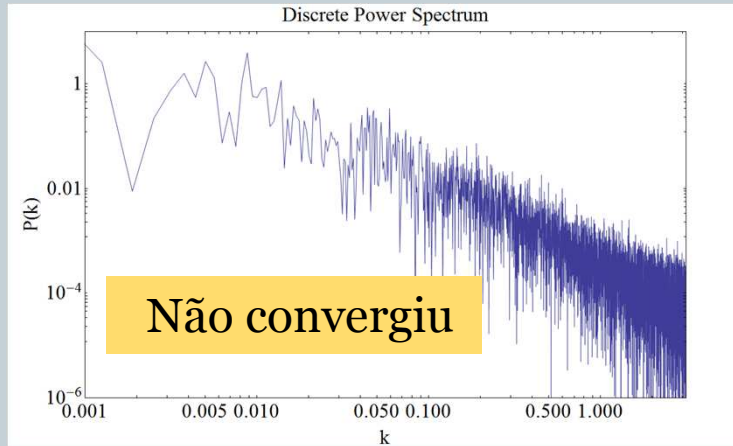
**Forte Não-Gaussianidade não  
é bem vinda!!**

# Testes de Convergência



- Gelman-Rubin
  - Teste Rápido e Prático
  - Não muito preciso
  - Comparação entre a variância das médias das  $N$  cadeias com a variância da cadeia
- Espectro de Potência
  - Mais eficaz que o teste de Gelman-Rubin
  - Mais demorado, escalando quadráticamente com a distribuição
  - Passos pequenos: Random Walk
  - Passos Grandes: Pontos descorrelacionados

# Espectro de Potência



Semelhanças entre: A cadeia que não convergiu, o Random Walk e cadeia convergida ( $k > 0.1$ )

# Otimização do Método



- Escolher a função teste “parecida” com a distribuição desejada
  - Funciona bem para casos Gaussianos
  - Usar a própria distribuição como função teste nem sempre ajuda (Caso Extremo: Bimodal)
- Outras otimizações podem ser testadas, mas:

**“The onus is on you to prove any new method leaves the target distribution invariant” – Antony Lewis**

# Conclusões



- MCMC é uma ferramenta mais rápida que a grid para dimensões mais altas ( $D > 4$ )
- Distribuições fortemente não-gaussianas não são facilmente representadas
- É importante sempre checar a convergência do método
- Qualquer modificação no algoritmo deve manter a distribuição alvo invariante