

Aula 19

Aula passada

- Otimização
- Caixeiro viajante
- *Hill Climbing*
- Distribuição de Boltzman
- Simulated Annealing
- De volta ao caixeiro

Aula de hoje

- Problemas
- Monte Carlo na moda
- Caminho trilhado
- Desafios
- Avaliação

Problemas da Aula 1

- **Amostragem**

- dado conjunto de objetos, função de probabilidade f , gerar amostras seguindo f
- ex. todos os alunos do Brasil, escolher indivíduo com probabilidade proporcional CRA

- **Somatório / Integral**

- Calcular o valor de um somatório ou integral qualquer
- ex. calcular a probabilidade de um algoritmo fechar o jogo de paciência

- **Otimização**

- conjunto de objetos, função que avalia cada objeto, encontrar objetos de maior valor
- ex. todas as permutações de n cidades, encontrar permutação que minimiza distâncias

Monte Carlo to the Rescue

Atacam todos estes problemas!

- Conjunto de técnicas para atacar problemas como estes (otimização, cálculo e amostragem)
 - algoritmos ou métodos de Monte Carlo
- Muitas técnicas e algoritmos diferentes
 - surgiu na década de 40, grande expansão de uso na computação nas últimas duas décadas
- Ideia central da técnica: **aleatoriedade**
 - usar o acaso (a chance) para computar

Monte Carlo está na Moda

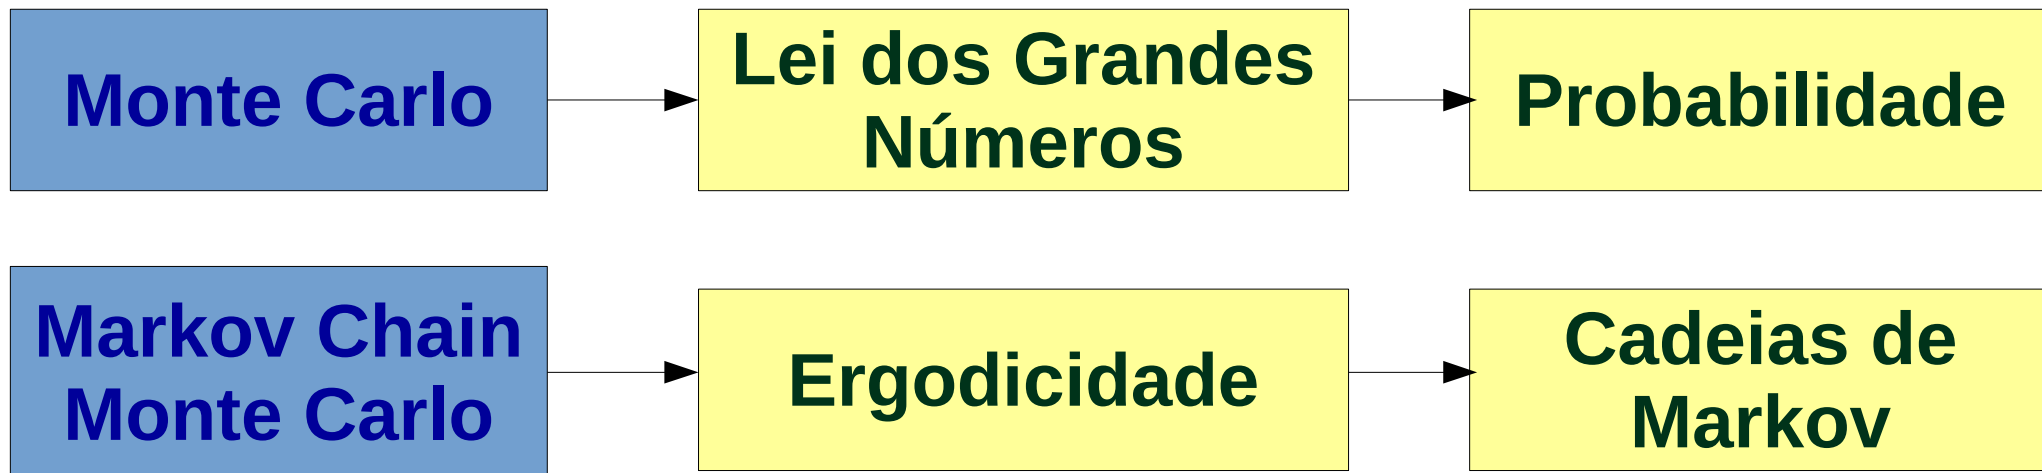
- Computação clássica
 - encontrar algoritmos provadamente eficientes para solução exata
- Computação moderna
 - encontrar algoritmos em geral eficientes que em geral dão boas soluções

Mudança de paradigma!

- Fomentado pela mudança na complexidade dos problemas sendo atacados
 - ex. algoritmo que dirige um carro!
- **Aleatoriedade:** técnica central da computação moderna
 - algoritmos de Monte Carlo incorporam tais técnicas e permitem rigor matemático

Monte Carlo nesta Disciplina

- Objetivo foi descobrir e se familiarizar com conceitos teóricos e técnicas fundamentais
 - permitem entender o que está por de trás de Monte Carlo
 - não iremos aprofundar em nenhuma aplicação específica (em seu projeto sim)



Estudaremos o amarelo para
melhor entender o azul!

Caminho Trilhado (1/2)

- Logística, apresentação e motivação (1 aula)
- Revisão de probabilidade (2 aulas)
 - eventos, independência, Bayes, v.a., binomial, valor esperado, conjunta
- Desigualdades e Lei dos grandes números (2 aulas)
 - Markov, Chebyshev, Chernoff, limitante da união, erro e confiança
- Monte Carlo para estimar somatório/integral (1 aula)
 - variância, erro
- Monte Carlo para gerar amostras (2 aulas)
 - transformada inversa, rejeição, *importance sampling*, simulação

Caminho Trilhado (2/2)

- Cadeia de Markov (3 aulas)
 - definição, distribuição no tempo, propriedades, distribuição estacionária, convergência, reversibilidade, decomposição em autovetores, tempo de mistura, vão espectral
- Markov Chain Monte Carlo (3 aulas)
 - caminho amostral, simulação, teorema ergódico, gerando amostras, Metropolis-Hastings, Gibbs Sampling
- *Simulated Annealing* (1 aula)
 - Distribuição de Boltzmann, definição, convergência, estratégia de resfriamento
- Encerramento (1 aula)
 - aula de hoje

Monte Carlo e Você

- Vimos muitos conceitos, muitos resultados, muitas técnicas
 - visão geral da teoria sem focar em problemas específicos
- Ainda há muito a ser explorado
 - tanto na teoria quanto na prática
 - muitas aplicações com soluções específicas
- Monte Carlo é cada vez mais usado (e não compreendido)
 - fração de pessoas que entendem MCMC está indo a zero
 - mas não o número de pessoas, que cresce
- Buscar entender e aplicar no seu problema

MC como *Building Block*

- Cada vez mais aplicações vem empregando métodos de aprendizado
 - *AI everywhere!*
- Técnicas de aprendizado de máquina como *building blocks* para solução de problemas
 - fatorização de matrizes, clusterização de pontos, redes neurais
 - *frameworks* prontos para uso: Tensor Flow
- Monte Carlo muitas vezes empregado como *building blocks* destas técnicas
 - amostragem, estimação, otimização
 - *Building block do building block!*

Muitos Desafios Científicos

- Quantas amostras são necessárias (para garantir um erro $\varepsilon > 0$)?
 - ex. tempo de mistura em CM, geração de amostras para aproximar somatório
- Qual CM devemos usar para gerar amostras ou buscar por solução ótima?
 - ex. para aplicar Metropolis-Hastings, Gibbs Sampling, ou simulated annealing
 - *expander graphs*: estrutura promissora

Perguntas importantes e difíceis

- na teoria e na prática, de forma generalizada ou em problemas específicos

Fim



- Perguntas e/ou comentários?