

Aula 12

Aula passada

- Cadeias de Markov
- Definição e exemplos
- Modelo On-Off
- Sem memória
- Distribuição no tempo
- Irredutibilidade
- Aperiodicidade

Aula de hoje

- Distribuição estacionária
- Tempo de chegada
- Distância de variação total
- Convergência
- Reversibilidade
- Passeios aleatórios
- Nascimento e morte

Cadeia de Markov

- Seja S o espaço de estados da CM, e P a matriz de transição de estados
- Seja X_t uma v.a. que determina o valor do estado da cadeia no instante de tempo t , para $t = 0, 1, 2, \dots$
- Estamos interessados em
 - $P[X_t = s] = \pi_s(t)$
- Sabemos que para um estado inicial, temos
$$\pi(t) = \pi(t-1)P = \pi(0)P^t$$

Mas para onde vai $\pi(t)$?

- será que depende em $\pi(0)$?

Possível Convergência

- Observação 1: X_t não converge
 - X_t passeia pela cadeia para sempre, trocando de estado
- Observação 2: $P[X_t = s_i]$ pode convergir
 - Prob. de encontrar X_t no estado s_i , ou fração de vezes que X_t visita o estado s_i (intuitivamente)
- Estamos interessados em valores grandes de t
$$\lim_{t \rightarrow \infty} \pi(t) = \lim_{t \rightarrow \infty} \pi(0) P^t$$
 - mas temos que formalizar este limite


Distribuição Estacionária

- Seja π um vetor de distribuição em uma CM com matriz de transição P
- Dizemos que π (vetor linha) é uma distribuição estacionária sse

$$\pi_s \geq 0 \quad \sum_{s \in S} \pi_s = 1 \quad \longleftarrow \text{Vetor de probabilidade}$$
$$\pi P = \pi \quad \longrightarrow \quad \pi_i = \sum_j \pi_j P_{ji} \quad , \text{ para todo } i$$

- Ou seja, ao multiplicar π por P temos π de volta
 - “estacionou”, não temos mais dinâmica!
- Repare que se $\pi(0)$ é uma distribuição estacionária, então $\pi(1) = \pi(0)P = \pi(0)$

Exemplo Modelo On-Off



$$P = \begin{pmatrix} .75 & .25 \\ .67 & .33 \end{pmatrix}$$

$$\pi = (8/11 \quad 3/11) \longleftarrow \text{Distribuição estacionária}$$

- Verificando: $\pi P = ?$

$$\pi_1 = 8/11 * 3/4 + 3/11 * 2/3 = 8/11$$

$$\pi_2 = 8/11 * 1/4 + 3/11 * 1/3 = 3/11$$

- Se $\pi(0) = \pi$ então temos que $\pi(1) = \pi(0)P = \pi$
 - vetor de probabilidade está estacionado!

Tempo de Chegada

- T_{ij} : Tempo necessário para sair de um estado s_i e chegar a outro estado s_j (*hitting time*)
 - número de transições, T_{ij} é aleatório, $\tau_{ij} = E[T_{ij}]$
$$T_{ij} = \min \{ t \mid X_t = s_j \wedge X_0 = s_i \}$$
- Se $i = j$, temos τ_{ii} , chamado de tempo médio de retorno ao estado s_i
 - número médio de transições para sair e voltar ao estado s_i
- T_{ij} não depende de $\pi(t)$ pois estamos condicionando em estar em s_i

Tempo de Chegada

- Teorema: Para qualquer CM irredutível e aperiódica, para qualquer dois estados s_i e s_j , temos o seguinte:

$$P[T_{ij} < \infty] = 1$$

- Probabilidade de T_{ij} ser infinito é zero
- Não há chances de sair de s_i ficar circulando pela cadeia e nunca chegar a s_j

$$E[T_{ij}] = \tau_{ij} < \infty$$

- Valor esperado do tempo de retorno para qualquer estado s_i é finito
- Boa notícia!


Distribuição Estacionária e Tempo de Retorno

- Teorema: Para qualquer CM irredutível e aperiódica, para qualquer estado s_i , temos a seguinte relação

$$\pi_i = \frac{1}{\tau_{ii}}$$

- Relação entre tempo médio de retorno e distribuição estacionária
- Conhecer um determina o outro!
- **Intuição:** na média o processo visita s_i 1 vez a cada τ_{ii} passos

Exemplo



$$P = \begin{pmatrix} .75 & .25 \\ .67 & .33 \end{pmatrix}$$

$$\pi = (8/11 \quad 3/11)$$

- Tempo médio de retorno do estado On (1) e Off (2) ?
- $\tau_{11} = 1/\pi_1 = 11/8 = 1.375$
- $\tau_{22} = 1/\pi_2 = 11/3 = 3.666$

Variação Total

- Como medir a distância entre dois vetores?
 - Precisamos disso para medir aproximação da distribuição estacionária
 - há muitas maneiras, uma delas é variação total
- Seja α e β dois vetores de probabilidade em S , a distância de variação total entre eles é dada por
$$d_{TV}(\alpha, \beta) = \frac{1}{2} \sum_k |\alpha_k - \beta_k| \quad \longleftarrow d_{TV} \text{ tem valor entre 0 e 1}$$
- Sequência de vetores α_t converge para β em variação total sse
$$\lim_{t \rightarrow \infty} d_{TV}(\alpha_t, \beta) = 0$$

Convergência de CM

- Teorema: Para qualquer CM irredutível e aperiódica, para qualquer condição inicial $\pi(0)$, temos que

$$\lim_{t \rightarrow \infty} d_{TV}(\pi(t), \pi) = 0 \quad \longleftarrow \quad \pi \text{ é uma distribuição estacionária da CM}$$

- Além disso, π é única!
 - CM sempre converge para a mesma distribuição estacionária, independente da condição inicial
 - Também chamado de estado estacionário, ou equilíbrio da CM

Encontrando π

- Ótima notícia, mas como encontrar π ?

1) Método iterativo

$$\pi(t) = \pi(t-1)P = \pi(0)P^t$$

- fazer iteração até critério de convergência

2) Método direto

$$\pi = \pi P$$

- resolver sistema de equações, adicionando a equação


$$\sum_i \pi_i = 1$$

3) Monte Carlo

- Usar própria cadeia para gerar amostras para estimar π_i ou estimar τ_{ij} para todo s_i

Modelo On-Off

- Distribuição estacionária?
- Sistemas de equações



$$\pi_i = \sum_j \pi_j P_{ji} \quad \sum_i \pi_i = 1$$

$$\pi_1 = \pi_1 P_{11} + \pi_2 P_{21} = (1-p)\pi_1 + q\pi_2$$

$$\pi_2 = \pi_1 P_{12} + \pi_2 P_{22} = p\pi_1 + (1-q)\pi_2$$

$$\pi_1 + \pi_2 = 1$$

- Substituindo $\pi_2 = 1 - \pi_1$ na primeira equação, temos

$$\pi_1 = (1-p)\pi_1 + q(1-\pi_1) \rightarrow \pi_1 = \frac{q}{p+q}$$

$$e \quad \pi_2 = \frac{p}{p+q}$$

Reversibilidade

- Uma classe bem especial de CM
 - usada por muitos algoritmos, incluindo MCMC
- Reversível no tempo: evolução de X_t é o mesmo se t vai para frente ou para trás
- Uma CM é dita reversível para a distribuição de probabilidade π sse


$$\pi_i P_{ij} = \pi_j P_{ji}$$

Massa de prob fluindo de s_i para s_j = Massa de prob fluindo de s_j para s_i

- Se π existe então π é também distribuição estacionária
- Uma forma ainda mais forte de equilíbrio!

Passeios Aleatórios

- Seja $G=(V, E)$ um grafo não direcionado
- Considere um andarilho que passeia pelo grafo de forma aleatória, sem preferência e sem memória
 - escolhe uniformemente próximo vértice entre vizinhos do vértice atual



- $p_{12} = 1/2$, $p_{13} = 1/2$, $p_{21} = 1/3$, $p_{23} = 1/3$, $p_{24} = 1/3$, ...

Passeios Aleatórios

- Nosso andarilho induz uma cadeia de Markov sobre o grafo G
 - forma de colocar o grafo em “movimento”
- X_t : vértice onde andarilho se encontra no tempo t
- Matriz de transição de probabilidade
 - D^{-1} é a matriz diagonal com o inverso do grau de cada vértice
 - A é a matriz de adjacência de G
- Outra forma: $P_{ij} = 1/d_i$ se (i, j) são vizinhos, 0 c.c.
 - onde d_i é o grau do vértice i

Passeios Aleatórios

- Qual a distribuição estacionária do andarilho ?

$$\pi_i = \frac{d_i}{K} \quad K = \sum_i d_i = 2m \quad \leftarrow m \text{ é o número de arestas em } G$$


- **Incrível:** só depende do grau do vértice i
 - K é constante de normalização
 - Todos os vértices com mesmo grau em igual prob
- Além disso, esta CM é reversível

$$\pi_i P_{ij} = \pi_j P_{ji} \quad \leftarrow \text{Podemos verificar}$$

- tanto faz andarilho andar para frente ou para trás
- equilíbrio mais forte para esta CM

Exemplo

Andarilho




$$K = \sum_i d_i = 2m = 24$$

$$\pi = \left(\frac{2}{24} \quad \frac{3}{24} \quad \frac{3}{24} \quad \frac{5}{24} \quad \frac{3}{24} \quad \frac{3}{24} \quad \frac{3}{24} \quad \frac{2}{24} \right)$$

- Independente de onde andarilho inicia, distribuição de sua posição converge para π
 - prob de encontrar o andarilho no vértice i

Processo de Nascimento e Morte (*Birth-Death*)


- Generalização do modelo On-Off para mais estados
 - CM muito utilizada, várias aplicações práticas
- K estados: $1, \dots, K$
- Transições apenas entre estados vizinhos (com possível *loops*)
 - matriz P é tridiagonal



- Em geral, $p_{i,i+1}$ e $p_{i+1,i}$ possuem alguma lei de formação
 - modelo possui ainda mais regularidade

Processo de Nascimento e Morte (*Birth-Death*)

- Qual é a distribuição estacionária?



- Assumindo que CM é reversível, temos $\pi_i P_{ij} = \pi_j P_{ji}$
- Vamos definir π como possível candidato, e assumir algum valor para π_1 . Temos então

$$\pi_2 = \frac{\pi_1 P_{12}}{P_{21}} \quad \pi_3 = \frac{\pi_2 P_{23}}{P_{32}} = \frac{\pi_1 P_{12} P_{23}}{P_{21} P_{32}} \quad \dots \quad \pi_i = \frac{\pi_1 \prod_{j=1}^{i-1} P_{j,j+1}}{\prod_{j=1}^{i-1} P_{j+1,j}}$$

Processo de Nascimento e Morte (*Birth-Death*)

- Mas quanto vale π_1 ?

$$1 = \sum_{i=1}^K \pi_i = \sum_{i=1}^K \frac{\pi_1 \prod_{j=1}^{i-1} P_{j,j+1}}{\prod_{j=1}^{i-1} P_{j+1,j}} = \pi_1 \sum_{i=1}^K \frac{\prod_{j=1}^{i-1} P_{j,j+1}}{\prod_{j=1}^{i-1} P_{j+1,j}}$$

- Logo,
$$\pi_1 = \left(\sum_{i=1}^K \frac{\prod_{j=1}^{i-1} P_{j,j+1}}{\prod_{j=1}^{i-1} P_{j+1,j}} \right)^{-1}$$

- Modelo BD é reversível, e π é sua distrib estacionária

Exemplo da Fila

- Considere uma fila onde a cada instante tempo chega ou sai um objeto da fila
 - chegada: com prob p , saída: com prob q , $p+q < 1$
 - fila tem capacidade para armazenar K objetos
- Modelo BD com $K+1$ estados (fila vazia + K)
 - $P_{i,i+1} = p$, $i=0, \dots, K-1$; $P_{i+1,i} = q$ $i=1, \dots, K$; $P_{i,i} = 1-p-q$
- Estado estacionário?

$$\pi_i = \frac{\pi_0 \prod_{j=1}^i P_{j,j+1}}{\prod_{j=1}^i P_{j+1,j}} = \pi_0 \left(\frac{p}{q} \right)^i$$
$$\pi_0 = \left(\sum_{i=0}^K \left(\frac{p}{q} \right)^i \right)^{-1} = \frac{1 - p/q}{1 - (p/q)^{K+1}}$$

, para $p < q$

Exemplo da Fila

- $K=10$, $p=0.3$ (chegada), $q=0.4$ (saída)
- Aplicando as fórmulas temos

$$\pi_0 = \frac{1 - 0.3/0.4}{1 - (0.3/0.4)^{10+1}} = 0.261 \quad \pi_i = \pi_0 \left(\frac{0.3}{0.4} \right)^i$$

- Probabilidade da fila estar vazia?

$$\pi_0 = 0.261$$


- Probabilidade da fila estar cheia?

$$\pi_K = 0.015$$

- Valor esperado do tamanho da fila?

$$\sum_{i=0}^K i \pi_i = \dots$$

Outro Exemplo



- CM é irredutível? **Sim!**
- CM é aperiódica? **Sim!**
- Qual é sua distribuição estacionária?
 - por inspeção, sem fazer conta
 $\pi_i = \frac{1}{4}$ para $i = 1, 2, 3, 4$
- Podemos verificar facilmente!
- CM é reversível? **Não!**
$$\pi_1 p_{12} = \frac{1}{4} \frac{6}{10} = \frac{3}{20} \neq \pi_2 p_{21} = \frac{1}{4} \frac{3}{10} = \frac{3}{40}$$
- **Intuição:** processo gira mais em uma direção (anti-horário)
 - direção do tempo (para frente ou para trás) determina direção mais girada, não sendo reversível