

Seminarium magisterskie 2

Metody Monte Carlo z wykorzystaniem łańcuchów Markowa

Magdalena Trafidło

2 czerwca 2023

- Problem: Chcielibyśmy próbkować z rozkładu π , którego gęstość jest skomplikowanej postaci.
- Propozycja: Metody Monte Carlo + łańcuchy Markowa.

Łańcuchy Markowa z czasem dyskretnym

- $E = \{e_1, \dots, e_m\}$ - przestrzeń stanów,
- $\{X_n\}$ - łańcuch Markowa, jeśli:

$$\begin{aligned} & \mathbb{P}(X_n = e_j | X_{n-1} = e_i, X_{n-2} = e_{i_{n-2}}, \dots, X_0 = e_{i_0}) = \\ & = \mathbb{P}(X_n = e_j | X_{n-1} = e_i) = P_{ij}, \end{aligned}$$

- $\mathbb{P} = (P_{ij})$ - macierz przejść, stochastyczna
- π - rozkład stacjonarny, jeśli $\pi\mathbb{P} = \pi$,
- $\{X_n\}$ - ergodyczny, jeśli $\{X_n\}$ - nieredukowalny i nieokresowy.

- $\{X_n\}$ - ergodyczny $\implies \{X_n\}$ ma dokładnie jeden rozkład stacjonarny, dla dowolnych i, j $\lim_{t \rightarrow \infty} P_{ij}^t = \pi(j)$,
- $\{X_n\}$ - odwracalny: istnieje takie π , że dla dowolnych i, j $\pi(i)P_{ij} = \pi(j)P_{ji}$.

Markov Chain Monte Carlo (MCMC)

- Problem: Chcielibyśmy próbkować z rozkładu π , którego gęstość jest skomplikowanej postaci.
- Rozwiązanie: Konstruujemy łańcuch Markowa, którego rozkład stacjonarny to π i z niego próbkujemy.

Hard-core model

$G = (V, K)$ - graf, gdzie:

- V - zbiór wierzchołków.
- K - zbiór krawędzi.

Konfiguracja: Przypisanie każdemu z wierzchołków 0 albo 1

Konfiguracja dopuszczalna: żadne dwa wierzchołki z przypisaną 1 nie mogą być połączone ze sobą krawędzią:

$$\forall v, w \in V : (v, w) \in K \implies e(v)e(w) = 0.$$

Niech Z_G - liczba wszystkich dopuszczalnych konfiguracji,

$$e \in S = \{0, 1\}^V,$$

$$\pi(e) = \begin{cases} 1/Z_G, & e \text{ - dopuszczalna} \\ 0, & \text{w.p.p.} \end{cases}$$

Algorytm:

- 1 Niech X_k będzie w jednej z dopuszczalnych konfiguracji e .
- 2 Wybieramy losowo wierzchołek v , z jednostajnym prawdopodobieństwem na V .
- 3 Generujemy $Z \sim \pi$:
 - 1 Dla $w \in V, w \neq v$ $Z(w) = e(w)$ ($Z_{-v} = e_{-v}$).
 - 2 Rzucamy monetą. Jeśli dostaniemy reszkę, i wszystkie wierzchołki sąsiadujące z v mają przypisaną wartość 0, zmieniamy wartość przy wierzchołku v na 1 ($Z(v) = 1$). W przeciwnym wypadku $Z(v) = 0$.
- 4 $X_{k+1} = Z$.

- 1 Niech X_k będzie w jednej z dopuszczalnych konfiguracji e .
- 2 Wybieramy losowo wierzchołek v , z jednostajnym prawdopodobieństwem na V .
- 3 Generujemy $Z \sim \pi$:
 - 1 Dla $w \in V, w \neq v$ $Z(w) = e(w)$ ($Z_{-v} = e_{-v}$).
 - 2 Przypisujemy wartość do $Z(v)$ zgodnie z warunkowym rozkładem stacjonarnym względem pozostałych wierzchołków:

$$\mathbb{P}(Z_v = s | Z_{-v} = e_{-v}), s \in S.$$

- 4 $X_{k+1} = Z$.

Przykład - kolorowanie grafu

$G = (V, K)$ - graf, $S = \{1, \dots, q\}$ - kolory.

Kolorujemy każdy z wierzchołków jednym z q kolorów.

Dopuszczalne kolorowanie: dwa sąsiadujące ze sobą wierzchołki nie mogą mieć tego samego koloru:

$$\forall v, w \in V : (v, w) \in K \implies e(v) \neq e(w).$$

Przykład - Problem plecakowy

Mamy d ponumerowanych przedmiotów. Niech

- $w = (w_1, \dots, w_d)$, $w_i \geq 0$ - wagi przedmiotów,
- $v = (v_1, \dots, v_d)$, $v_i \geq 0$ - wartości przedmiotów,
- W - maksymalne obciążenie plecaka,
- $x = (x_1, \dots, x_d)$ - konfiguracja, $x_i \in \{0, 1\}$, gdzie $x_i = 1$ oznacza, że bierzemy i -ty przedmiot.

Konfiguracja jest dopuszczalna, jeśli $\sum_{i=1}^d x_i w_i \leq W$.

Nasz cel:

znalezienie x maksymalizującego $\sum_{i=1}^d x_i v_i$, gdzie $\sum_{i=1}^d x_i w_i \leq W$.

Przykład - Problem plecakowy

$$\pi(x) = \frac{1}{c} \exp\left(\beta \sum_{i=1}^d v_i x_i\right), \text{ dla } x : \sum_{i=1}^d x_i w_i \leq W$$

- 1 $X_k = x = (x_1, \dots, x_d)$, $x_i \in \{0, 1\}$, x -dopuszczalna.
- 2 Wybieramy $x_i \in x$ z jednostajnym prawdopodobieństwem na x .
- 3 Generujemy $Z \sim \pi$:
 - 1 $Z_{-i} = x_{-i}$,
 - 2 $Z_i = 0$ z pr. $\frac{1}{1+\exp(\beta v_i)}$, $Z_i = 1$ z pr. $\frac{1}{1+\exp(-\beta v_i)}$.
- 4 $X_{k+1} = Z$.

Generujemy nowe X , i zapamiętujemy ten, który miał największą wartość.

$$\begin{aligned}\mathbb{P}(Z_i = 0 | Z_{-i} = x_{-i}) &= \frac{\mathbb{P}(Z_i = 0, Z_{-i} = x_{-i})}{\mathbb{P}(Z_i = 0, Z_{-i} = x_{-i}) + \mathbb{P}(Z_i = 1, Z_{-i} = x_{-i})} = \\ &= \frac{\exp\left(\beta \left(\sum_{j=1, j \neq i}^d v_j x_j + v_i \cdot 0\right)\right)}{\exp\left(\beta \sum_{j=1, j \neq i}^d v_j x_j + 0 \cdot \beta v_i\right) + \exp\left(\beta \sum_{j=1, j \neq i}^d v_j x_j + 1 \cdot \beta v_i\right)} = \\ &= \frac{\exp\left(\beta \sum_{j=1, j \neq i}^d v_i x_i\right)}{\exp\left(\beta \sum_{j=1, j \neq i}^d v_i x_i\right) + \exp\left(\beta \sum_{j=1, j \neq i}^d v_i x_i + \beta v_i\right)} = \frac{1}{1 + \exp(\beta v_i)}, \\ \mathbb{P}(Z_i = 1 | Z_{-i} = x_{-i}) &= 1 - \frac{1}{1 + \exp(\beta v_i)} = \frac{1}{1 + \exp(-\beta v_i)}.\end{aligned}$$

Przykład - Model Isinga

$G = (V, K)$ - graf, gdzie:

- V - zbiór wierzchołków.
- K - zbiór krawędzi.

Konfiguracja: Przypisanie każdemu z wierzchołków tzw spina $+1$ albo -1

Energia konfiguracji: $H(e) = \sum_{(v,w) \in K} e(v)e(w)$

$$\pi(e) = \frac{1}{c} \exp \left(\beta \sum_{(v,w) \in K} e(v)e(w) \right)$$

Przykład - Model Isinga

Niech $I = \{(u, w) \in K, u, w \neq v\}$, $J = \{w : (v, w) \in K\}$.

$$\begin{aligned} \mathbb{P}(Z(v) = 1 | Z_{-v} = e_{-v}) &= \\ & \frac{\mathbb{P}(Z(v) = 1, Z_{-v} = e_{-v})}{\mathbb{P}(Z(v) = 1, Z_{-v} = e_{-v}) + \mathbb{P}(Z(v) = -1, Z_{-v} = e_{-v})} = \\ & \frac{\exp(\beta[\sum_I e(u)e(w) + \sum_J 1 \cdot e(w)])}{\exp(\beta[\sum_I e(u)e(w) + \sum_J e(w)]) + \exp(\beta[\sum_I e(u)e(w) - \sum_J e(w)])} = \\ & \frac{1}{1 + \exp(-2\beta \sum_{w:(v,w) \in K} e(w))}, \end{aligned}$$

$$\mathbb{P}(Z(v) = -1 | Z_{-v} = e_{-v}) = \frac{1}{1 + \exp(2\beta \sum_{w:(v,w) \in K} e(w))}$$

Niech

- $E = \{e_1, \dots, e_M\}$ - przestrzeń stanów, konfiguracje,
- π - rozkład stacjonarny.

Chcemy generować z rozkładu π , ale nie znamy macierzy \mathbb{P} , która spełniałaby $\pi\mathbb{P} = \pi$.

Do znalezienia \mathbb{P} możemy użyć tzw rozkładu proponującego, opisanego macierzą przejść Q na przestrzeni stanów E , nieredukowalnego i nieokresowego łańcucha Markowa:

$$\mathbb{P}(e, e') = \begin{cases} Q(e, e') \min\left(1, \frac{\pi(e')}{\pi(e)}\right), & e' \neq e, \\ 1 - \sum_{e'' \in E, e'' \neq e} Q(e, e'') \min\left(1, \frac{\pi(e'')}{\pi(e)}\right), & e' = e. \end{cases}$$

Q - symetryczna macierz przejść,

Algorytm:

- 1 Niech X_k będzie w jednej z dopuszczalnych konfiguracji e .
- 2 Generujemy $Z \sim (Q(e, e_1), Q(e, e_2), \dots, Q(e, e_M))$ (lub w skrócie: $Z \sim Q(e, \cdot)$), powiedzmy że $Z = e'$.
- 3 Niech $\alpha = \min(1, \frac{\pi(e')}{\pi(e)})$.
- 4 Generujemy $U \sim U(0, 1)$. Jeśli $U < \alpha$, to $X_{k+1} = e'$, w przeciwnym przypadku $X_{k+1} = X_k$.

Q - niesymetryczna macierz przejść,

Algorytm:

- 1 Niech X_k będzie w jednej z dopuszczalnych konfiguracji e .
- 2 Generujemy $Z \sim (Q(e, e_1), Q(e, e_2), \dots, Q(e, e_M))$ (lub w skrócie: $Z \sim Q(e, \cdot)$), powiedzmy że $Z = e'$.
- 3 Niech $\alpha = \min \left(1, \frac{Q(e', e)\pi(e')}{Q(e, e')\pi(e)} \right)$.
- 4 Generujemy $U \sim U(0, 1)$. Jeśli $U < \alpha$, to $X_{k+1} = e'$, w przeciwnym przypadku $X_{k+1} = X_k$.

Problem plecakowy - algorytm Metropolisa

- $x = (x_1, \dots, x_d) \in \{0, 1\}^d$,
- $\pi(x) = \frac{1}{c} \exp\left(\beta \sum_{i=1}^d v_i x_i\right)$, dla $x : \sum_{i=1}^d x_i w_i \leq W$.

Niech

$$Q(x, x') = \begin{cases} \frac{1}{d}, & \sum_i |x_i - x'_i| = 1 \\ 0 & \text{w.p.p} \end{cases}$$

Algorytm:

- 1 Niech $X_k = x, x : \sum_{i=1}^d x_i w_i$.
- 2 Generujemy $Z \sim Q(x, \cdot)$, powiedzmy że $Z = x'$.
- 3 Niech $\alpha = \min(1, \frac{\pi(x')}{\pi(x)})$.
- 4 Generujemy $U \sim U(0, 1)$. Jeśli $U < \alpha$, to $X_{k+1} = x'$, w przeciwnym przypadku $X_{k+1} = X_k$.

Problem plecakowy - algorytm Metropolisa

$$\begin{aligned} \frac{Q(x', x)\pi(x')}{Q(x, x')\pi(x)} &= \frac{\exp\left(\beta \sum_{i=1}^d v_i x'_i\right)}{\exp\left(\beta \sum_{i=1}^d v_i x_i\right)} = \frac{\exp\left(\beta \sum_{i=1, i \neq j}^d v_i x'_i + \beta v_j x'_j\right)}{\exp\left(\beta \sum_{i=1, i \neq j}^d v_i x_i + \beta v_j x_j\right)} = \\ &= \frac{\exp\left(\beta \sum_{i=1, i \neq j}^d v_i x_i + \beta v_j x'_j\right)}{\exp\left(\beta \sum_{i=1, i \neq j}^d v_i x_i + \beta v_j x_j\right)} = \frac{\exp\left(\beta v_j x'_j\right)}{\exp\left(\beta v_j x_j\right)} = \frac{\exp\left(\beta v_j (1 - x_j)\right)}{\exp\left(\beta v_j x_j\right)} = \\ &= \exp(-\beta v_j (2x_j - 1)) \end{aligned}$$

Miara probabilistyczna π jest monotoniczna na $E = S^V$ jeśli $\forall e \leq e', \forall v \in V : \pi(e_{-v}) > 0, \pi(e'_{-v}) > 0$ mamy:

$$\mathbb{P}(z(v) \leq s | z_{-v} = e_{-v}) \geq \mathbb{P}(z(v) \leq s | z_{-v} = e'_{-v}) \quad \forall s \in S$$

natomiast jest antymonotoniczna jeśli zachodzi:

$$\mathbb{P}(z(v) \leq s | z_{-v} = e_{-v}) \leq \mathbb{P}(z(v) \leq s | z_{-v} = e'_{-v}) \quad \forall s \in S.$$

Mówimy, że funkcja aktualizująca φ jest monotoniczna względem \leq jeśli:

$$\forall i, j \in E : (i \leq j) \forall U \in [0, 1] \varphi(i, u) \leq \varphi(j, u).$$

Coupling from the past(CFTP)

- 1 Niech $n=1$.
- 2 Startujemy dwa łańcuchy w chwili $-N_n$, jeden w minimalnym stanie (0), drugi w maksymalnym stanie (M), do chwili 0, używając takiej samej funkcji aktualizującej φ , i używając takich samych $U_{-N-1}, \dots, U_1, U_0 \sim U(0, 1)$.
- 3 Jeśli w chwili 0 oba łańcuchy znajdą się w tym samym stanie e , zwracamy e i kończymy. W przeciwnym przypadku: $n = n + 1$, idziemy do kroku 2 i używamy poprzednio wygenerowanych U_i dla nowego n .

- Andrzej Ruciński, Wykład 9: Markov Chain Monte Carlo
- Maciej Romaniuk, Metody Monte-Carlo i MCMC
- Bartosz Chmiela, Locally-informed proposals in Metropolis-Hastings algorithm with applications