

**Hard-core model.** Mamy dany graf  $G = (V, K)$ , gdzie  $V = \{v_1, \dots, v_M\}$  (wierzchołki) oraz  $K$  jest zbiorem krawędzi. Do każdego wierzchołka przypisujemy *spin*  $-1$  lub  $+1$ , każde takie przypisanie nazywamy *konfiguracją*.

$\xi \in \{-1, +1\}^V$  jest natomiast *poprawną konfiguracją* (PK) jeśli żadne 2 wierzchołki, które są sąsiadami w grafie  $G$  nie mają oba wartości  $+1$ .

Na wykładzie podana była konstrukcja MCMC (Gibbs sampler), którego przestrzeń stanów jest zbiorem wszystkich możliwych poprawnych konfiguracji, a rozkładem stacjonarnym jest rozkład jednostajny:

$$\pi_G(\xi) = \begin{cases} \frac{1}{Z_G} & \text{jeśli } \xi \in PK \\ 0 & \text{w p.p.} \end{cases},$$

gdzie  $Z_G$  jest stałą normalizacyjną, tj.  $Z_G = \sum_{\xi \in \{0,1\}^V} \mathbf{1}(\xi \in PK)$ .

1. Pokaż, że algorytm Gibbs dla modelu hard-core jest *nieredukowalnym* łańcuchem Markowa.
2. Pokaż, że dla każdego wierzchołka  $v \in V$ , warunkowe prawdopodobieństwo, że  $v$  przyjmuje wartość  $+1$ , pod warunkiem, że wszyscy sąsiedzi mają wartość  $-1$ , wynosi  $1/2$ .
3. Rozważmy następujący **uogólniony hard-core model**. Model ten pozwala na różne "intensywności  $+1$ " w grafie. Jest to zrobione poprzez wprowadzenie parametru  $\lambda > 0$ . W tym modelu każda poprawna konfiguracja ma prawdopodobieństwo

$$\pi_{G,\lambda}(\xi) = \begin{cases} \frac{\lambda^{\eta(\xi)}}{Z_{G,\lambda}} & \text{jeśli } \xi \in PK \\ 0 & \text{w p.p.} \end{cases},$$

gdzie  $\eta(\xi)$  jest liczbą "plus jedynek" w konfiguracji  $\xi$ , a  $Z_{G,\lambda}$  jest stałą normalizacyjną, tj.  $Z_{G,\lambda} = \sum_{\xi \in \{0,1\}^V} \lambda^{\eta(\xi)} \mathbf{1}(\xi \in PK)$ .

Udowodnij, że dla każdego wierzchołka  $v \in V$ , warunkowe prawdopodobieństwo, że  $v$  przyjmuje wartość  $+1$ , pod warunkiem, że wszyscy sąsiedzi mają wartość  $-1$ , wynosi  $\frac{\lambda}{\lambda + 1}$ .

4. Skonstruuj algorytm MCMC dla uogólnionego modelu hard-core.

5. Łańcuch Markowa  $X$  o macierzy przejść  $\mathbf{P}$  na przestrzeni stanów  $E = \{\mathbf{e}_1, \dots, \mathbf{e}_N\}$  z porządkiem częściowym  $\preceq$  nazywa się *stochastycznie monotonicznym* jeśli:

$$\forall(\mathbf{e}_i \preceq \mathbf{e}_j) \forall(A \in \mathcal{U}) \quad P(\mathbf{e}_i, A) \leq P(\mathbf{e}_j, A),$$

gdzie  $\mathcal{U}$  jest klasą tzw. zbiorów górnych, tzn.  $A \in \mathcal{U}$  jeśli mamy następującą implikację:  $(\mathbf{e}_i \preceq \mathbf{e}_j, i \in A) \Rightarrow (j \in A)$  (słownie: jeśli mamy dwa porównywalne stany, i mniejszy z nich należy do  $A$ , to większy też musi należeć do  $A$ ).

Podaj warunki na to, by proces urodzin i śmierci z macierzą przejścia podaną w zad. 1 na Liście 6. był stochastycznie monotoniczny względem porządku liniowego  $\leq$ .

6. Funkcją updatującą jest *monotoniczna* względem porządku częściowego  $\preceq$  jeśli

$$\forall(\mathbf{e}_i \preceq \mathbf{e}_j) \quad \forall(u \in [0, 1]) \quad \phi(\mathbf{e}_i, u) \preceq \phi(\mathbf{e}_j, u)$$

Z kolei łańcuch Markowa o macierzy przejść  $\mathbf{P}$  jest *realizowalnie monotoniczny* jeśli istnieje monotoniczna funkcja updatująca.

Dla zadania 4. z Listy 5. wskaż (względem porządku liniowego)

- a) Poprawną i monotoniczną funkcję updatującą.
  - b) Poprawną, ale nie monotoniczną funkcję updatującą.
7. Podaj warunki na to, by proces urodzin i śmierci z macierzą przejścia podaną w zad. 1 na Liście 6. był realizowalnie monotoniczny względem porządku liniowego  $\leq$  (i wskaż wówczas monotoniczną funkcję updatującą).
8. Przypomnij algorytm CFTP (Coupling From The Past), omów jego działanie na przykładzie poprzedniego zadania.