

Monte Carlo - metoda výpočtu deterministických veličin náhodnými algoritmy

Příklad:  $\Omega \subset [0,1]^d$ , najít měru  $|\Omega|$ ... Lebesgueova míra  $\Omega$ .

- Předpokládáme, že
- $\int_{[0,1]^d} \chi_{\Omega}(x) dx$  nelze jednoduše a přesně spočítat
  - pro bod  $x \in [0,1]^d$  lze jednoduše rozhodnout jestli  $x \in \Omega$  nebo  $x \notin \Omega$ .

$$\Rightarrow |\Omega| = \int_{\Omega} 1 dx = \int_{[0,1]^d} \chi_{\Omega}(x) dx \text{ nahradíme } \frac{1}{m} \sum_{i=1}^m \chi_{\Omega}(x_i),$$

kde  $x_i \in [0,1]^d$  jsou volány náhodně a rovnoměrně rozděleny!

...obecně  $EX$  nahradíme  $\frac{1}{m} \sum_{j=1}^m X_j$

Jaká je průměrná chyba?!

$$E \left| EX - \frac{1}{m} \sum_{j=1}^m X_j \right|^2 = E \left| \frac{1}{m} \sum_{j=1}^m (EX - X_j) \right|^2$$

$$= \frac{1}{m^2} E \sum_{j,k=1}^m (EX - X_j)(EX - X_k) = \frac{1}{m^2} \sum_{j=1}^m E (EX - X_j)^2 = \frac{m \sigma^2}{m^2}$$

$\Rightarrow$  Průměrná chyba (v  $L_2$ -smyslu) je tedy  $\frac{\sigma}{\sqrt{m}}$ , kde  $\sigma^2 = \text{var}(X)$

a  $m$  je počet opakování.

# Příklady metody Monte Carlo:

• Výpočet  $\pi$ :  $[0;1]^2$ ,  $\Omega = \{(x_1, x_2) \in [0;1]^2, x_1^2 + x_2^2 \leq 1\}$

$$(x_1, x_2) \in [0;1]^2 \text{ rovnoměrně, } X = \begin{cases} 1 & (x_1, x_2) \in \Omega \\ 0 & (x_1, x_2) \notin \Omega \end{cases}$$

$E X = \pi/4$  --- Volíme  $(x_1, x_2)$  náhodně a počítáme podíl těch, kteří padnou do jednotkového kruhu...


• Podobně funguje experiment s jehlou délky 1 ležící náhodně

na rovinně přímky se vzdáleností 1:

- $x$  --- vzdálenost středu jehly od nejbližší přímky  $\in [0; 1/2]$
- $\alpha$  --- úhel mezi jehlou a přímkami  $\alpha \in [0; \pi/2]$

$$B = \{(x, \alpha) \in [0; 1/2] \times [0; \pi/2] : 0 \leq x \leq \frac{1}{2} \sin \alpha\}$$

$$\mathbb{P}(B) = \frac{4}{\pi} \int_0^{\pi/2} \frac{1}{2} \sin \alpha d\alpha = \frac{2}{\pi}$$



--- Buffon 1777, Laplace 1812

• Vlastnosti nachodných polygonů

Sylvester (1864): Pro konvexní  $K \subset \mathbb{R}^2$  zvolíme náhodně  $x_1, \dots, x_4 \in K$ .

Jaká je pravděpodobnost, že  $\text{conv}(x_1, \dots, x_4)$  je trojúhelník?

--- stačí spočítat střední hodnotu plochy  $\text{conv}(x_1, x_2, x_3)$  ---

=> není rovinný integrál

--- možná simulovat metodou Monte Carlo

--- nebo spočítat analyticky

(známe hodnoty pro kruh, trojúhelník, ...)

Pokud je integrál tvaru  $I = \int_{[a;b]} f(x) \psi(x) dx$ , pak lze brát

$$\frac{1}{m} \sum_{i=1}^m f(x_i), \text{ kde ale } x_i \text{ jsou brány náhodně s hustotou } \psi$$

$$\bullet X = f(x), EX = \int f(x) \psi(x) dx = I.$$

=> Pro použití metody Monte Carlo je nutné u nás generovat náhodné vzorky  $(x_i)$  vzhledem k dané distribuci.

... Vyrobíme Markovův řetězec, který bude mít danou distribuci jako stacionární rozdělení a vezmeme  $X_m$  pro  $m$  velkou!

=> Pro  $S$  a  $\pi$  na  $S$  dáváme Markovský řetězec tak, aby

- $\pi$  byl stacionární stav ...  $\pi = \pi P$
- $X_m$  konvergovalo rychle k  $\pi$  (v nějakém smyslu)  
... tedy aby  $P(X_m = j) \sim \pi_j$  pro  $m$  malou.
- Další podmínky ...  $X_m \rightarrow X_{m+1}$  lze realizovat rychle

Mějme tedy dáno  $S$  a  $\pi$  na  $S$ .

Metropolisův algoritmus:

- Předpokládáme, že na  $S$  máme (nerozdělitelný) Markovský řetězec se symetrickou maticí pravděpodobnosti přechodu  $(\Upsilon_{x,y})_{x,y \in S}$
- Modifikujeme tento řetězec tak, aby měl stac. rozdělení  $\pi$ .
- V každé  $x \neq y$  akceptujeme s pravd.  $a(x,y)$ , odmitáme s  $1 - a(x,y)$

$$\text{Tedy } P_{xy} = \begin{cases} \Upsilon_{xy} a(x,y), & y \neq x \\ 1 - \sum_{y \neq x} \Upsilon_{xy} a(x,y), & y = x \end{cases}$$

- $\pi$  bude stac. pro  $P$ , pokud budou splněny rovnice detailní rovnováhy:

$$\pi(x) P_{xy} = \pi(y) P_{yx}, \quad x \neq y$$

$$\text{tedy } \pi(x) \Upsilon_{xy} a(x,y) = \pi(y) \Upsilon_{yx} a(y,x)$$

$\Upsilon$  symetrická

$$\pi(x) a(x,y) = \pi(y) a(y,x)$$

a chceme volit co nejvíce ( $\Rightarrow$  rychlost konvergence)

$$\Rightarrow \pi(x) a(x,y) = \pi(y) a(y,x) = \min(\pi(x), \pi(y))$$

$$\dots a(x,y) = \frac{\min(\pi(x), \pi(y))}{\pi(x)}, \quad a(y,x) = \frac{\min(\pi(x), \pi(y))}{\pi(y)}$$

$$= \min\left(1, \frac{\pi(y)}{\pi(x)}\right)$$

$$\Rightarrow P_{xy} = \begin{cases} \Upsilon_{xy} \cdot \min\left(1, \frac{\pi(y)}{\pi(x)}\right), & x \neq y \\ 1 - \sum_{y \neq x} \Upsilon_{xy} \cdot \min\left(1, \frac{\pi(y)}{\pi(x)}\right), & x = y \end{cases}$$

Poznamky: • Metropolisův algoritmus patří mezi jít na  
pochůdku  $\pi(x)/\pi(y)$

Pokud  $h: S \rightarrow \mathbb{R}_+$  a  $\pi(x) = \frac{h(x)}{Z}$ ,  $Z = \sum_{x \in S} h(x)$

(tedy  $\pi$  je známá až na normalizační konstantu  $Z$ ),  
pak  $\pi(x)/\pi(y) = h(x)/h(y)$  a  $Z$  nemusí být počítat.

• Pokud  $\Psi$  není symetrická (ale je uvažovatelná)

$$P(x,y) = \Psi(x,y) \cdot \min \left\{ 1, \frac{\pi(y) \Psi(y,x)}{\pi(x) \Psi(x,y)} \right\}, x \neq y$$

$$= 1 - \sum_{z \neq x} \dots \quad , x=y$$

Příklady: •  $(V,E)$ -graf, obarvený  $q$ -barvami

$$f: V \rightarrow \{1, \dots, q\}$$

Množina všech obarvení:  $\{1, \dots, q\}^V$

Vlastní obarvení - sousední vrcholy mají různou barvu

... Pro všechny hrany  $\{v,w\} \in E: f(v) \neq f(w)$

$S =$  množina vlastních obarvení  $(V,E)$   $q$ -barvami

- nezávislá velikost  $S$

Chceme generovat prvky  $S$  uniformně:  $\pi(f) = \frac{1}{\#S}$ . -55-

Glauberova dynamika vlastních  $q$ -obarvení je následující řetězec:

- pro konfiguraci  $f$  a vrchol  $v$  v grafu,  $i$  barva  $j \in \{1, \dots, q\}$  je "dovolená", pokud je různá od barv všech sousedů:  $j \neq f(w), w \sim v$

- Řetězec:
- vybereme  $v \in V$  náhodně (rovnoměrně)
  - vybereme náhodně (rovnoměrně) jednu z dovolených barv  $j$
  - Obarvíme  $v$  barvou  $j$ .

Tento řetězec má jako stac. rozdělení rovnoměrné rozdělení na  $S$ :

- Mezi dvěma konfiguracemi  $f, g$  lze přejít jen tehdy když liší-li se v jednom vrcholu  $v$

$$\mathbb{P}(X_{m+1} = g | X_m = f) = \frac{1}{\#V} \cdot \frac{1}{\#\{j: j \text{ je dovolená v } v\}}$$

↑  
vybereme  $v$

$$= \mathbb{P}(X_{m+1} = f | X_m = g) \quad \dots \quad \mathbb{P}(f|g) = \mathbb{P}(g|f)$$

... rovnice detailně rovnováhy pro rovnoměrné rozdělení!

- další příklad: "hardcore configuration"

Do vrcholů grafu  $(V, E)$  umístíme částice tak, aby žádné dvě nesousedily

$$S = \{ f: \{0, 1\} \rightarrow V : f(v) \cdot f(w) = 0 \text{ pro } vw \}$$

Řetězec pro výběr náhodné hardcore configuration:

- Vybereme náhodně rovnoměrně vrchol  $v \in V$  bez ohledu na jeho obsazení
- Je-li nějaký soused obsazen ( $\exists w \in V: vw \text{ \& } f(w) = 1$ ) necháme  $v$  neobsazen ( $f(v) = 0$ )
- jinak je  $v$   $\mathbb{P} = \frac{1}{2}$  obsazené a  $\mathbb{P} = \frac{1}{2}$  neobsazené.

## 7.4 Ising model

The *Ising model* is a fundamental model of statistical physics. Let us assume that we have a  $d$ -dimensional grid with  $N \times N \times \cdots \times N$  points. Later on, we stick to  $d = 2$  with  $N^2$  vertices as the most transparent (and most understood) system.<sup>11</sup> The vertices are neighbours if (and only if) they differ only in one coordinate by the value 1.




Figure 1:  $11 \times 11$  grid in  $\mathbb{R}^2$  with  $11^2$  vertices, some of them with an assigned spin.

There are  $2^{N^2}$  ways, how one can assign a spin  $\{-1, +1\}$  to each of these vertices. We define a probability distribution on all these  $2^{N^2}$  possible ways, how to distribute the spin across the grid. This will make some of the assignments more likely than the others. To describe the details, we need some notation. We denote the set of vertices of the grid by  $V$  and we denote by  $v \sim w$  the fact, that  $v$  and  $w$  are neighbours. If  $\sigma : V \rightarrow \{-1, +1\}$  is an assignments of spins to the vertices, we denote by  $H(\sigma)$  its *energy*

$$H(\sigma) = - \sum_{\substack{v, w \in V \\ v \sim w}} \sigma(v)\sigma(w).$$

The idea behind this formula is clear: if two neighbouring vertices have the same spin (i.e.,  $\sigma(v) = \sigma(w) = +1$  or  $\sigma(v) = \sigma(w) = -1$ ), then the energy is decreased by 1, if the spins differ, then  $\sigma(v) \cdot \sigma(w) = -1$  and the energy is increased. So,  $H(\sigma)$  is the number of pairs of neighbouring vertices with different spin minus the number of pairs of neighbouring vertices with the same spin.

The probability distribution on all mappings  $\sigma : V \rightarrow \{-1, +1\}$  is then proportional to  $e^{-\beta H(\sigma)}$ , where  $\beta > 0$  is a real parameter. This means that

$$\mu(\sigma) = \frac{1}{Z(\beta)} e^{-\beta H(\sigma)}$$

and

$$Z(\beta) := \sum_{\sigma} e^{-\beta H(\sigma)}$$

is the normalization factor, which ensures that  $\sum_{\sigma} \mu(\sigma) = 1$ .

Some of the properties of this model are easy to observe, namely

<sup>11</sup>In general, one can consider an arbitrary graph  $G = (V, E)$  instead.

- The probability space of all  $\sigma$ 's is huge, it has  $2^{N^2}$  elements.
- For a given  $\sigma$ ,  $H(\sigma)$  is quite easy to compute.
- It is rather difficult to compute  $Z(\beta)$  as it would require to calculate the (huge) sum over all  $\sigma$ 's.
- However, for two different  $\sigma_1$  and  $\sigma_2$ , the ratio  $\mu(\sigma_1)/\mu(\sigma_2)$  is again easy to compute, as the normalization factor  $Z(\beta)$  cancels out.

We are mainly interested in two (somehow connected) questions

- How does a typical configuration of  $\sigma$  chosen randomly with respect to  $\mu$  look like? Is it more random or is it more structured?
- How do we generate a random sample with respect to  $\mu$ ?

The question about the typical configuration of  $\sigma$  is rather tricky. From the  $2^{N^2}$  configurations, vast majority is rather chaotic, but their energy  $H(\sigma)$  is large (we expect them to have many neighbours with different spin) and, therefore,  $\mu(\sigma)$  is very small. The “structured” configurations, with large areas in the grid of vertices with the same spin, are much less in number, but their energy  $H(\sigma)$  is very small making  $\mu(\sigma)$  large.

It turns out, that the parameter  $\beta$  plays a crucial role. In  $d = 2$ , there is a *phase transition*: For small values of  $\beta$  (or large values of the temperature  $T = 1/\beta$ ) the values of  $H(\sigma)$  (and of  $\mu(\sigma)$ ) do not differ much and the random configuration is rather chaotic. For large values of  $\beta$  (and small values of  $T$ ) structured configurations are more likely. Somewhere inbetween is the *critical temperature* ( $\beta = \ln(1 + \sqrt{2})/2$ ). The analytical description of this solution was given by Lars Onsager in 1944. The analytical solution for  $d \geq 3$  is unknown so far.




Figure 2: Low, critical, and high temperature on  $250 \times 250$  grid, from the book of David Levin and Yuval Peres.

To answer the second question, namely to generate random spin configurations with respect to  $\mu$ , one can use the Markov Chain Monte Carlo method. We construct a Markov Chain on the state space  $\mathbb{S} = \{-1, +1\}^{N^2}$ , which has stationary distribution  $\mu$ , we start randomly and iterate for long enough until the actual state is (almost) random with respect to  $\mu$ . For that sake, we use the *Glauber dynamics*, which starts with arbitrary  $\sigma$ , and then

repeatedly picks a vertex  $w$  randomly and uniformly from all vertices and then re-defines the spin of  $w$  randomly.