

Metoda Monte Carlo - úvodní poznámky

- jde o stochastickou metodu - používáme náhodná (nebo častěji pseudonáhodná) čísla a veličiny, abychom nasimulovali určitý fyzikální systém, nebo určili průměrné hodnoty pozorovatelných veličin mnohočásticového systému

- používají se různé typy simulací:

1) MC integrace více-rozměrných integrálů -

- základní technika

- lze využít v mnoha oborech

2) geometrické MC - simulace specifických fyzikálních systémů, kde je obtížné použít jiné metody

- např. simulace difúze pomocí náhodných procházek nebo perkolace náhodnou depozicí částic apod.

3) termodynamické MC - vychází z ergodické hypotézy

- střední hodnoty veličin přes náhodné konfigurace systému, ne přes časový vývoj

- ilustrace na Isingově modelu

4) kinetické MC - simulace časového vývoje složitěho systému náhodným výběrem procesů, které se v určitý čas stanou

- viz letní se-sestr - Pokročilé simulace ...

atd.

- lze zvládnout velké počty částic, až 10^6 a více

- není potřeba velká paměť, ale dostatek výpočetního času

a dobrý generátor (pseudo)náhodných čísel

- nejde o ab initio metodu, pouze aproximace

- je snadná na naprogramování

Metoda Monte Carlo - základní pojmy

- použití metody MC většinou obnáší výpočet

určité veličiny (např. integrálu) pomocí průměrování

přes stochastické (náhodné) veličiny X_i ,

kteřé mají určité rozdělení pravděpodobnosti

- díky centrální limitní větě (viz podrobněji níže)

chyba výpočtu obecně klesá s rostoucím počtem n

průměrovacích veličin jako $\frac{1}{\sqrt{n}}$ (alespoň s velkou pravděpodobností)

• základní statistické pojmy:

- pravděpodobnostní funkce náhodné diskrétní veličiny X

$P[X=x] = P(x)$ udává pravděpodobnost, že

náhodná veličina X bude mít hodnotu x ,

musí tedy platit $P(x) \geq 0$ pro $\forall x$ a $\sum_x P(x) = 1$

- distribuční funkce náhodné diskrétní veličiny X

$F(x) = P[X \leq x] = \sum_{t \leq x} P(t)$ (tež CDF = kumulativní distribuční funkce)

a tedy $P[x_1 \leq X \leq x_2] = F(x_2) - F(x_1)$,

jde o neklesající funkci s hodnotami $0 \leq F(x) \leq 1$

- rozdělení pravděpodobnosti spojité náhodné veličiny X

se určuje pomocí hustoty pravděpodobnosti $g(x) \geq 0$

splňující $\int_{\mathcal{X}} g(x) dx = 1$, kde \mathcal{X} je definiční obor X ,

pak pravděpodobnost, že X bude mít hodnotu v (x_1, x_2)

je $P[x_1 \leq X \leq x_2] = \int_{x_1}^{x_2} g(x) dx = F(x_2) - F(x_1)$

kde $F(x)$ je distribuční funkce spojité náhodné veličiny X

$$F(x) = P[X \leq x] = \int_{-\infty}^x g(t) dt \quad \text{a tedy} \quad g(x) = \frac{dF(x)}{dx}$$

(pozn.: pravděpodobnost nalezení přesné hodnoty x pro spojitou náhodnou veličinu X je nulová)

- střední hodnota veličiny X (vážený průměr přes dané rozdělení)

$$E(X) = \sum_{i=1}^n x_i p_i \quad \text{pro diskrétní náhodnou veličinu}$$

$$= \int_{-\infty}^{\infty} x g(x) dx \quad \text{pro spojitou}$$

- rozptyl, neboli střední kvadratická odchylka (tež variance)

$$\begin{aligned} \sigma^2(X) = D(X) = \text{var}(X) &= \sum_{i=1}^n [x_i - E(X)]^2 p_i = \sum_{i=1}^n x_i^2 p_i - E(X)^2 \quad \text{pro diskrétní} \\ &= \int_{-\infty}^{\infty} [x - E(X)]^2 g(x) dx = \int_{-\infty}^{\infty} x^2 g(x) dx - E(X)^2 \quad \text{pro spojitou} \\ &= E(X^2) - E(X)^2 \end{aligned}$$

člen $-2x_i E(X)$ dá $-2E(X)^2$
náhodnou veličinu

- základní vlastnosti $E(x)$ a $D(x)$:

$$E(X+c) = c + E(X)$$

$$E(cX) = cE(X)$$

$$D(X+c) = D(X)$$

$$D(cX) = c^2 D(X)$$

a pro dvě nezávislé náhodné veličiny X a Y

$$E(X+Y) = E(X) + E(Y) \quad D(X+Y) = D(X) + D(Y)$$

$$E(X \cdot Y) = E(X) \cdot E(Y) \quad D(cX) = c^2 D(X)$$

např. $D(X+Y) = \iint_{\mathbb{R}^2} [x+y - E(X+Y)]^2 g(x,y) dx dy =$ ↙ pro nezávislé X a Y

$$\begin{aligned} &= \iint [x - E(X) + y - E(Y)]^2 g_x(x) g_y(y) dx dy = \\ &= \iint [(x - E(X))^2 + \underbrace{2(x - E(X))(y - E(Y))}_{=0} + (y - E(Y))^2] g_x(x) g_y(y) dx dy = \\ &= D(X) + D(Y) \end{aligned}$$

- střední hodnota funkce náhodné veličiny X


pokud $Y = f(X)$ je nová náhodná veličina, pak

$$E(Y) = E(f(X)) = \int_a^b f(x) g(x) dx \quad (\text{nebo } = \sum_{i=1}^n f(x_i) p_i)$$

a obecně $E(f(X)) \neq f(E(X))$

• příklady rozdělení

1) rovnoměrné rozdělení na intervalu $\langle a, b \rangle$



$$g(x) = \begin{cases} \frac{1}{b-a} & \text{na } \langle a, b \rangle \\ 0 & \text{jinde} \end{cases} \quad (\text{pro } \langle 0, 1 \rangle \text{ bude } g(x) = 1)$$

$$E(X) = \frac{a+b}{2}, \quad D(X) = \sigma^2(X) = \frac{(b-a)^2}{12}, \quad F(X) = \frac{x-a}{b-a} \text{ na } \langle a, b \rangle$$


2) normální rozdělení $N(\mu, \sigma^2)$ na $\langle -\infty, \infty \rangle$

$$g(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

$$E(X) = \mu, \quad D(X) = \sigma^2$$

$$F(x) = \int_{-\infty}^x g(t) dt = \frac{1}{2} \left[1 + \text{Erf} \left(\frac{x-\mu}{\sqrt{2\sigma^2}} \right) \right], \quad \text{kde } \text{Erf}(z) = \frac{2}{\sqrt{\pi}} \int_0^z e^{-t^2} dt$$

(error function)



a tedy

$$P[x_1 \leq X \leq x_2] = \int_{x_1}^{x_2} g(t) dt = \frac{1}{2} \left[\text{Erf} \left(\frac{x_2-\mu}{\sqrt{2\sigma^2}} \right) - \text{Erf} \left(\frac{x_1-\mu}{\sqrt{2\sigma^2}} \right) \right]$$

pravidlo 3σ

$$P[\mu - 3\sigma \leq X \leq \mu + 3\sigma] = \text{Erf} \left(\frac{3}{\sqrt{2}} \right) = 0,9973...$$

a tedy náhodné měření leží téměř vždy v tomto intervalu

- pravděpodobná chyba náhodné veličiny X (pro normální rozdělení)

- máme-li jediné měření X s normálním rozdělením,

pak s velkou pravděpodobností bude ležet v intervalu

$\langle \mu - 3\sigma, \mu + 3\sigma \rangle$ a absolutní chyba (od střední hodnoty μ)

bude řádu tzv. pravděpodobné chyby $r \approx 0,67\sigma$

určené ze vztahu $P[\mu - r \leq X \leq \mu + r] = \frac{1}{2}$

• centrální limitní věta

- máme n nezávislých náhodných veličin X_1, \dots, X_n ,
které mají stejné rozdělení pravděpodobnosti,
tj. jejich střední hodnoty a rozptyly jsou stejné:

$$\begin{aligned} E(X_i) &= m \\ D(X_i) &= b^2 \quad \text{pro } i=1, \dots, n, \end{aligned}$$

pak pro jejich součet (tj. novou náhodnou veličinu)

$$S_n = X_1 + X_2 + \dots + X_n$$

platí (plyne přímou z $E(X+Y) = E(X) + E(Y)$ a obdobně pro $D(X+Y)$)

$$E(S_n) = nm \quad \text{a} \quad D(S_n) = nb^2.$$

Vvažujme dále normální rozdělení $N(\mu, \sigma^2)$,

kde $\mu = nm$ a $\sigma^2 = nb^2$, s hustotou pravděpodobnosti $g_n(x)$.

Pak centrální limitní věta říká, že

$$P[s_1 \leq S_n \leq s_2] \approx \int_{s_1}^{s_2} g_n(x) dx$$

pro libovolné s_1 a s_2 a všechna dostatečně velká n .

Neboli rozdělení součtů S_n velkého množství nezávislých náhodných veličin je přibližně normální.

Pozn: existují zobecnění pro mnohem slabší podmínky

např. X_1, \dots, X_n nemusí mít nutně stejné rozdělení

a ani nemusí být úplně nezávislé, důležité je,

aby jedna z veličin nebrala příliš velkou roli.

Díky tomu se normální rozdělení často objevuje v přírodě,

kde má na výsledek často vliv řada náhodných faktorů.

o odhad chyby metody Monte Carlo

- počítáme-li určitou veličinu A jako průměr náhodných veličin X_1, \dots, X_n , tj.

$$A_n = \frac{X_1 + X_2 + \dots + X_n}{n}$$

se středními hodnotami $E(X_i) = m$ a rozptyly $D(X_i) = b^2$,

pak podle centrální limitní věty bude pravděpodobnostní rozdělení A_n přibližně normální s

$$E(A_n) = \frac{\sum_{i=1}^n E(X_i)}{n} = m$$

a

$$D(A_n) = \frac{\sum_{i=1}^n D(X_i)}{n^2} = \frac{b^2}{n} \quad \text{neboli} \quad \boxed{\sigma = \frac{b}{\sqrt{n}}}$$

než $D(cX) = c^2 D(X)$

a tedy

$$P\left[m - \frac{3b}{\sqrt{n}} \leq A_n \leq m + \frac{3b}{\sqrt{n}}\right] \cong 0,9973 \dots$$

neboli

$$P\left[\left|\frac{1}{n} \sum_{i=1}^n X_i - m\right| < \frac{3b}{\sqrt{n}}\right] \cong 0,9973$$

a pravděpodobná chyba A_n tedy přibližně je

$$\boxed{r \cong 0,67\sigma = 0,67 \frac{b}{\sqrt{n}}}$$

a lze ji tedy očekávat řádu $\frac{1}{\sqrt{n}}$

- pozor!, nejde o horní odhad chyby, ale o pravděpodobnou chybu,

tj. skutečná chyba A_n od přesné hodnoty A může být ve skutečnosti větší, ale pravděpodobnost toho je velmi malá.