

MC metoda - opakování

- ① Formulovat úlohu jako střední hodnotu funkce f náhodné proměnné x :

$$\langle f \rangle = \int_{\Omega} f(x) p(x) dx$$

$$\langle f \rangle = \sum_i f(x_i) p_i$$

spojitá náhodná prom. x

$x \in \Omega$... hodnoty

$p(x)$ na Ω ... distrib. funkce

(pravděpodobnostní rozdělení)

míra $p(x)dx$

diskrétní: $x \in \{x_i\}$

pravděpodobnosti: $\{p_i\}$

- ② Nahradit středováním přes statistický soubor:

$x \rightarrow \{\xi_1, \xi_2, \xi_3, \dots, \xi_N\}$

$$\langle f \rangle \approx \frac{1}{N} \sum_i f(\xi_i) \xrightarrow{N \rightarrow \infty} \langle f \rangle$$

- ③ Pak platí: zákon velkých čísel \Rightarrow

Centrální limit věta: $\frac{1}{N} \sum_{i=1}^N f(\xi_i)$

je kolem $\langle f \rangle$ rozděleno Gaussovsky
S chybou $\sigma = \frac{\sigma_f}{\sqrt{N}}$

Použití na integraci — integrace MC Monte Carlo

přímocáré: $\int_{\Omega} f(\vec{x}) d\vec{x} = \langle f(\vec{x}) \rangle_V$ kde \vec{x} rozdělena rovnoměrně v obl. Ω

$\approx \frac{V_{\Omega}}{N} \sum_{i=1}^N f(\vec{x}_i)$ $\hookrightarrow p(\vec{x}) = \frac{1}{V_{\Omega}}$ konst. \leftarrow objem Ω

... chyba $\sim \frac{\sigma_f}{\sqrt{N}}$ $\sigma_f^2 = \langle (f - \langle f \rangle)^2 \rangle = \int_{\Omega} [f(\vec{x}) - \langle f \rangle]^2 d\vec{x}$


pozni: složitost implementace ani chyba nezávisí na dimenzi $d \dots \vec{x} \in \mathbb{R}^d$

! σ_f může! PŘ: peak šířky $L < 1$ v oblasti délky 1

$V \langle f \rangle \approx f \cdot L^d$

$\sigma_f^2 = \langle f^2 \rangle - \langle f \rangle^2 \approx f^2 L^d - f^2 L^{2d} \approx f^2 L^d$

\hookrightarrow relat. chyba $\approx \frac{\sigma_f}{\sqrt{N}} \cdot \frac{1}{\langle f \rangle V} \approx \frac{1}{\sqrt{N}} \frac{1}{f L^d} = \frac{1}{\sqrt{N} L^d}$... diverguje pro $d \rightarrow \infty$

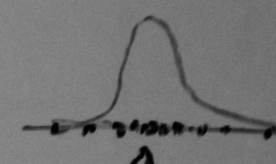


Optimalizace MC integrace ... nerovnoměrné rozdělení!

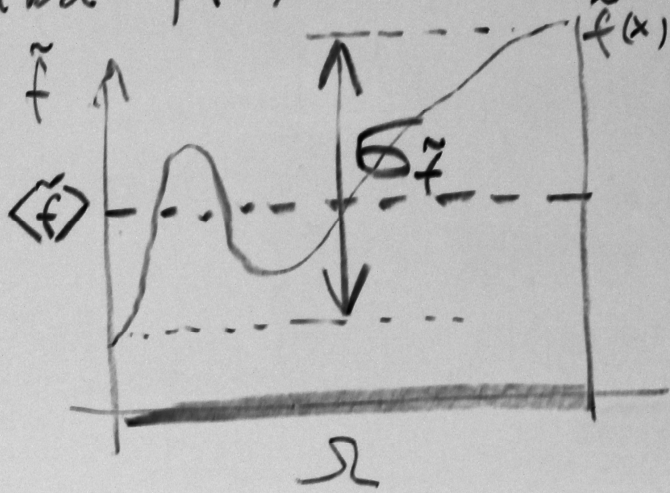
$$I = \int_{\Omega} f(x) dx = \int_{\Omega} \frac{f(x)}{p(x)} p(x) dx \quad \dots \text{nová fce } \tilde{f}(x) = \frac{f(x)}{p(x)}$$

\therefore nová náhodná proměnná \tilde{x} :
 $x \in \Omega$

$$I = \langle \tilde{f} \rangle_{\tilde{x}} \approx \frac{1}{N} \sum_{i=1}^N \tilde{f}(\xi_i)$$

pravd. rozdělení $p(x)$: 
 Stat. soubor $x \rightarrow \{\xi_1, \xi_2, \xi_3, \dots, \xi_N\}$

Volba $p(x)$... minimalizovat variaci $\sigma_{\tilde{f}}$ fce $\tilde{f} = \frac{f(x)}{p(x)}$



\rightarrow snažba, aby $\tilde{f} \sim \text{konst.}$

t.j. $p(x) \sim f(x) \cdot c$


(a přitom jsme uměli generovat $\{\xi_i\}$ s rozdělením $p(x)$)

8 Monte Carlo Methods

Table 8.1 Monte Carlo evaluation of the integral (8.4) using two different weight functions, $w(x)$. The exact value is 0.78540.

N	$w(x)=1$		$w(x)=\frac{1}{3}(4-2x)$	
	I	σ_I	I	σ_I
10	0.81491	0.04638	0.79982	0.00418
20	0.73535	0.03392	0.79071	0.00392
50	0.79606	0.02259	0.78472	0.00258
100	0.79513	0.01632	0.78838	0.00194
200	0.78677	0.01108	0.78529	0.00140
500	0.78242	0.00719	0.78428	0.00091
1000	0.78809	0.00508	0.78524	0.00064
2000	0.78790	0.00363	0.78648	0.00045
5000	0.78963	0.00227	0.78530	0.00028

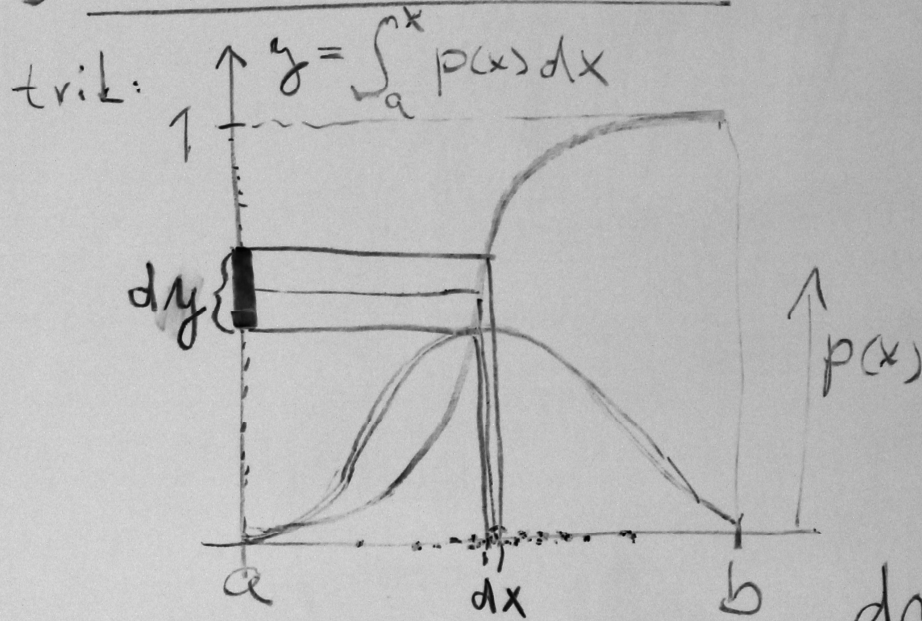
Prüfung: $I = \int_0^1 \frac{dx}{1+x^2} = \frac{\pi}{4} \doteq 0.78540$



$$w(x) = \frac{1}{3}(4-2x)$$

Generování náhodné proměnné s předem danou distribuční funkcí

① Přímá metoda 1D



náhodná prom $X \in (a, b) \dots p(x)$

\downarrow rovnoměrné rozl. $y \in (0, 1)$

$\left\{ \begin{matrix} (y) \\ i \end{matrix} \right\} \longleftrightarrow \left\{ \begin{matrix} (x) \\ i \end{matrix} \right\} = X \left[\left\{ \begin{matrix} (y) \\ i \end{matrix} \right\} \right]$

$y[X]$... inverze $X[y]$

počet bodů:


$$dm = N dy = N y' dx = N p(x) dx$$

Návod: (A) najít $y(x) \equiv \int_a^x p(t) dt$ a $y^{-1} \equiv X[y]$

(B) generovat rovnoměrné $y \in (0, 1) \rightarrow \left\{ \begin{matrix} (y) \\ i \end{matrix} \right\}_{i=1}^N$
 $\rightarrow \left\{ \begin{matrix} (x) \\ i \end{matrix} \right\}_{i=1}^N = X \left[\left\{ \begin{matrix} (y) \\ i \end{matrix} \right\}_{i=1}^N \right] \dots$ dá soubor

pozn: pokud nelze analyticky $\int_a^x p(x)$ nebo y^{-1}
je třeba numericky

② von Neumann rejection (odhadování)



a) generujeme náhodně (rovnoměrně)
 $x_i \in \langle a, b \rangle$; $y_i \in \langle a, c \rangle$
 $c > p(x) \forall x$

b) hodnoty $y_i > p(x_i)$ zahodíme

hodnoty $y_i \leq p(x_i)$ přijmeme

do souboru $\{j = x_i\}$


pozn: dá se snadno zobecnit
do více dim:

generujeme $\vec{x}_i \in \Omega$ a $y_i \in \langle 0, c \rangle$

a podle $\begin{cases} y_i > p(\vec{x}_i) & \text{zahodíme} \\ y_i \leq p(\vec{x}_i) & \text{přijmeme} \end{cases}$

pozn: pokud nelze analyticky $\int p(x)$ nebo t_j^{-1}
je třeba numericky

② von Neumann rejection pro úzká rozdělení



... zahazujeme moc bodů
→ trvá dlouho

vybírání: Srovnáváme rozdělení
... $X \dots \bar{p}(x)$

a) generujeme rovnoměrně v oblasti
pod \bar{p} a b) přijímáme pod p

technické detaily postupu:

a) generujeme \vec{x}_i náhodnou prom s distr. fci $p(x)$
generujeme $t \in (0, 1)$ rovnoměrně: $y_i = t \bar{p}(x_i)$

b) $\begin{cases} y_i > p(x_i) & \text{zahodíme} \\ y_i \leq p(x_i) & \text{přijmeme} \end{cases} \quad \left\{ \vec{x}_i \right\} = \vec{X}_i$

③ Prímé metody pro Gaussovo (normální) rozđ.

$$p_0(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} \quad \dots \quad x \in \mathbb{R} \quad \dots \quad \text{rozdělení} \quad \langle x \rangle = 0$$

$$\sigma = 1$$

↳ generuje $\{\xi_i\}$

potom $\{\sigma(\xi_i + \mu)\} \equiv \{\xi_i\}$ $\langle \xi_i \rangle = \mu$
 přeskálování σ

stačí ↗

metoda ① vyžaduje spec. fci Erf(x) a její inverzi.

... jednodušší ... generovat najednou dvě $x_1, x_2 \dots p(\vec{x}) \sim e^{-\frac{x^2}{2}}$

platí: $e^{-\frac{1}{2}(x_1^2 + x_2^2)} dx_1 dx_2 = e^{-\frac{1}{2}r^2} \cdot r dr d\theta = e^{-t} dt d\theta$ kde $t = \frac{1}{2}r^2 = p_0(x_1) \cdot p_0(x_2)$

tj ekvivalentně generujeme $\theta \in (0, 2\pi)$ rovnoměrně

požitím ① ... $\int_0^t e^{-t} dt = 1 - e^{-t} \leftarrow t \in (0, \infty)$ s distr $p(t) = e^{-t}$

→ $y(t) = 1 - e^{-t} \dots t = y^{-1} = -\ln(1-y) \dots$ rovnoměrně $y \in (0, 1)$

pak $x_1 = \sqrt{-2 \ln(1-y)} \cos \theta$ a $x_2 = \sqrt{-2 \ln(1-y)} \sin \theta \dots$ Gauss.

③ Prímé metody pro Gaussovo (normální) rozř.

a) metoda: generujeme rovnoměrně $\theta \in (0, 2\pi)$

$$y \in (0, 1)$$

pak $x_1 = \sqrt{-2 \ln(1-y)} \cos \theta$

$$x_2 = \sqrt{-2 \ln(1-y)} \sin \theta \quad \text{jsou nezávislé Gauss}$$

náhodné prom $\langle x \rangle = 0 \quad \sigma = 1$

b) Jednoduchá přibližná metoda založená na
Centrální limitní větě

... náhodná prom $y \in (0, 1)$ rovnoměrně: $\langle y \rangle = \frac{1}{2}$
 $\sigma_y = \frac{1}{\sqrt{12}}$

návod: generujeme y_1, y_2, \dots, y_{12}

pak $x = \left[\sum_{i=1}^{12} y_i - 6 \right]$ je blízká normálnímu

VYŽKALŠEJTE


rozřeklení s $\langle x \rangle = 0$ a $\sigma = 1$

... chyba ditr. pro $x \in (-2, 2)$
je menší než 2%

④ Metropolisův algoritmus

Metropolis, Rosenbluth & Rose...
Teller & Teller 1953

(obecně metody založené na náhodné procházce,
Markovovský proces - řetězec)



náhodným procesem — Markov proces

s takovými pravidly, aby pro $N \rightarrow \infty$ byla hustota
bodů $\{\vec{x}_i\} \in \mathcal{R}$ předem daná distr. fce $p(\vec{x})$

pravidla konstrukce překvapivě jednoduchá
a flexibilní!

④ Metropolisův algoritmus

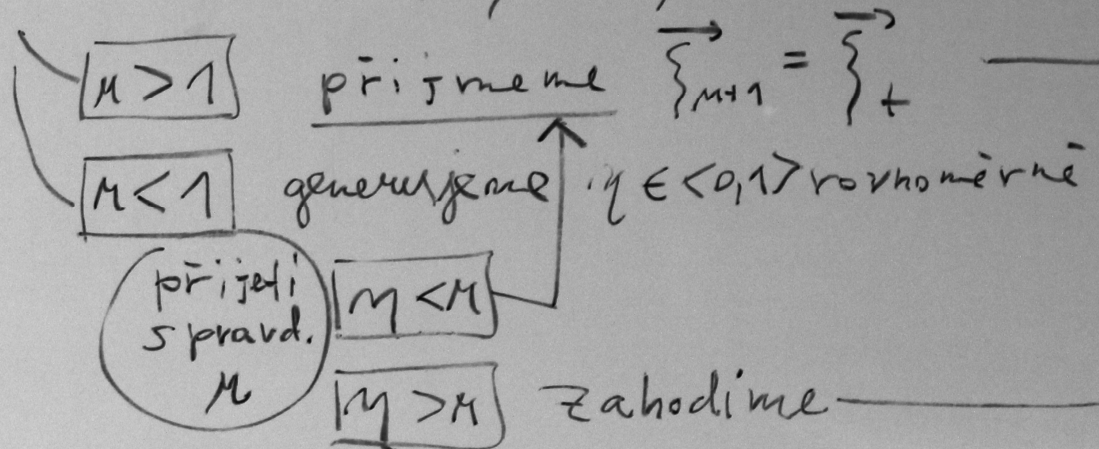
Metropolis, Rosenbluth & Rose...
Teller & Teller 1953

Algoritmus: ① vybrat \vec{x}_1

② z bodu \vec{x}_m pokusně vykročíme do \vec{x}_+
(např. rovnoměrně náhodně v δ -okolí \vec{x}_m)

OPAKOVAT
 $N \times$

③ def: $r \equiv p(\vec{x}_+) / p(\vec{x}_m)$




Tvrzení: $\{\vec{x}_m\}$ pro $N \rightarrow \infty$
jsou rozděleny s hust. pravd. $p(\vec{x})$

Náznak důkazu (intuitivní ... detailní rovnováha)

po dlouhé době ... distribuce \vec{x} kolem \bar{x} ... $p(\vec{x})$

$$N(x) = \nu p(x)$$



$$\Delta N(y) = N(x)P(x \rightarrow y)$$

$$- N(y)P(y \rightarrow x)$$

detailní rovnováha = 0

... ustálený stav p_e

$$t_j \quad \frac{P(y \rightarrow x)}{P(x \rightarrow y)} = \frac{N(x)}{N(y)} = \frac{p_e(x)}{p_e(y)} = \frac{p(x)}{p(y)}$$


potřebujeme ukázat $p_e(\vec{x}) \sim p(\vec{x})$ t_j

Náznak důkazu

v našem algoritmu:

$$P(X \rightarrow Y) = \frac{T(X \rightarrow Y)}{A(X \rightarrow Y)}$$

pravd. udělat krok do Y ... např.



jediný požadavek ... symetrické!

$$T(X \rightarrow Y) = T(Y \rightarrow X)$$

pravděpodobnost přijetí:

$$p(x) > p(y)$$

$$A(x \rightarrow y) = \frac{p(y)}{p(x)}$$

$$A(y \rightarrow x) = 1$$

$$p(y) > p(x)$$

$$A(y \rightarrow x) = \frac{p(x)}{p(y)}$$

$$A(x \rightarrow y) = 1$$

v obou příp.

$$\frac{p(y \rightarrow x)}{p(x \rightarrow y)}$$

$$= \frac{A(y \rightarrow x)}{A(x \rightarrow y)}$$

$$= \frac{1}{1} = 1$$

$$= \frac{p(x)}{p(y)}$$

(CBD QED) $\frac{p(x)}{p(y)}$

Komentáře a praktické otázky

• volba délky kroku δ

- malý ... skoro vše přijmeme; hodně kroků, abychom se někam dostali, následující ξ_n, ξ_{n+1} hodně korelované (závislé)
- velký ... hodně zahoříváme kroků (zpracovává), a pomalu vzorkujeme důležité obl., ale rychle propátráme velké oblasti (i oddělené)

Optimum ... cca $\frac{1}{2}$ kroků přijata

• volba poč. podmínky: vhodné relaxovat (pár kroků na poč. zahodit)

• statistická závislost nash. $\vec{\xi}_n, \vec{\xi}_{n+1}$

ODBOČKA: statistická závislost — korelace

dvě náhodné veličiny $a \dots p_a(a) \dots \left\{ \alpha_i \right\}_{i=1}^N$
 $b \dots p_b(b) \dots \left\{ \beta_i \right\}_{i=1}^N$

Def: korelační koeficient

$$C_{ab} \equiv \frac{\langle ab \rangle - \langle a \rangle \langle b \rangle}{\sigma_a \sigma_b} = \frac{\langle ab \rangle - \mu^2}{\underbrace{\langle a^2 \rangle - \mu^2}_{\sigma^2}}$$

pro totožné veličiny $\langle a \rangle = \langle b \rangle = \mu$; $\sigma_a = \sigma_b$

výpočet statist. souborem: $C_{ab} \leftarrow \frac{\sum_i (\alpha_i - \mu_a)(\beta_i - \mu_b)}{\sqrt{\sum_i (\alpha_i - \mu_a)^2} \sqrt{\sum_i (\beta_i - \mu_b)^2}}$

pozn: $C_{ab} = \frac{\langle (a - \mu_a)(b - \mu_b) \rangle}{\sigma_a \sigma_b}$

... důsl ... $-1 \leq C_{ab} \leq 1$... Schwartz ... $\frac{\langle x | y \rangle}{\|x\| \|y\|} = \cos \theta$

význam korelač. koef C_{ab} - statistická závislosť (ne)?

... (a, b) chápu jako 1 vektor náhod. prom. ... $p(a, b)$

$$\dots \text{tj } \langle ab \rangle = \iint ab p(a, b) da db$$

$$\langle a \rangle = \iint a [p(a, b) db] da = \int a p_a(a) da$$

$p_a(a)$

Statisticky nezávislé: $p(a, b) = p_a(a) p_b(b)$

... stat. vlast. a nezávislé na b ... $\langle f(a) \rangle \dots$ není $\neq p_a(a)$
 $\neq f$

$$\text{a } \langle ab \rangle = \iint ab p_a(a) p_b(b) da db = \langle a \rangle \langle b \rangle$$

\Rightarrow $C_{ab} = 0$

opacný extrém: 100% korelace

když naměříme $a \rightarrow d_i$ pak též $b: \beta_i = d_i$

tj. $\phi(a, b) = p_a(a) \delta(a-b) \dots p_a(x) = p_b(x) = p(x)$

$$\langle ab \rangle = \iint ab \delta(a-b) p(a) da db = \int a^2 p(a) da = \langle a^2 \rangle$$

tj. $\rho_{ab} = \frac{\sigma_a^2}{\sigma_a \sigma_a} = 1$

Význam pro posl. náhodných prom:

autokorelační fce $C_{\xi_0 \xi_k} = C(k) = \frac{\langle \xi_0 \xi_k \rangle - \langle \xi_0 \rangle^2}{\langle \xi_0^2 \rangle - \langle \xi_0 \rangle^2}$

prakticky spočítáme za předp. transl. invariance:

$$C(k) = \frac{\langle \xi_i \xi_{i+k} \rangle - \langle \xi_i \rangle^2}{\langle \xi_i^2 \rangle - \langle \xi_i \rangle^2}$$

+ přes soubor:

$$\langle \xi_i \xi_{i+k} \rangle = \frac{1}{N-k} \sum_{i=1}^{N-k} \xi_i \xi_{i+k}$$

