

Základní pojmy kolen centrální limity věty

- pravděpodobností funkce pro diskrétní náhodné veličiny X

$P[X=x] = P(x)$ udává pravděpodobnost, že náhodná veličina bude mit hodnotu x
 a tody $\sum_x P(x) = 1 \quad P(x) > 0$

- distribuční funkce diskrétní náh. veličin y

$$F(x) = P[X \leq x] \text{ je neklesající a spojite zprava}$$

$$= \sum_{t \leq x} P(t) \quad 0 \leq F(x) \leq 1$$

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

- rozdělení pravděpodobnosti spojité náhodné veličiny zahrnuje pouze

* hustoty pravděpodobnosti nebo hustoty rozdělení posti $g(x) > 0$

$$\int_{\Omega} g(x) dx = 1, \text{ kde } \Omega \text{ je definice obor } X$$

- pravděpodobnost, že náhodná veličina X bude mít hodnotu v (x_1, x_2) je

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

případě posti toho, že X bude mít hodnotu x_1 , je nula.

- distribuční funkce spojité náhodné veličiny

$$F(x) = P[X \leq x] = \int_{-\infty}^x g(t) dt \quad F(-\infty) = 0 \quad F(+\infty) = 1$$

komplementární distribuční funkce je $1 - F(x)$

$$\text{a dle } g(x) = \frac{dF(x)}{dx}$$

normalní (Gaussova) rozdělení posti $N(\mu, \sigma^2)$

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

* $N(0,1)$ tzv. normální (standardizované) norm. rozd.

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

* střední hodnota $E(x) = \sum_i x_i p_i$ (expecting value - tří MX apod.)

$$(\text{základní prvek daného rozdělení}) \quad = \int x g(x) dx = \mu \quad (\text{pro norm. rozdělení})$$

* rozptyl = střední kvadratická odchylnka = variance (sídy $D(x) \geq 0$)

$$\sigma^2(x) = D(x) = \operatorname{var}(x) = \sum_i [x_i - E(x)]^2 p_i = \sum_i x_i^2 p_i - [E(x)]^2$$

$$= \int_{-\infty}^{\infty} (x - E(x))^2 g(x) dx = \int_{-\infty}^{\infty} x^2 g(x) dx - [E(x)]^2$$

$$= E(x^2) - [E(x)]^2$$

Inverzní distribuční funkce $F^{-1}(x) =$ kumulativní funkce

$$\begin{aligned} E(x+c) &= c + E(x) & D(x+c) &= D(x) \\ E(cx) &= cE(x) & D(cx) &= c^2 D(x) \\ E(X+Y) &= E(X) + E(Y) & D(X+Y) &= D(X) + D(Y) \end{aligned}$$

zákon velkých čísel

- říká, že při velkém počtu nezávislých pokusů je vzdělání teor. hodnoty postupně blížit teoretické hodnotě pravděpodobnosti konvergenci

Basis theorem

slabá verze: nechť $\bar{X}_n = \frac{1}{n} (X_1 + X_2 + \dots + X_n)$, kde náhodné veličiny X_i jsou nezávislé a mají stejné rozdělení pravděpodobnosti
 říká, že $\bar{X}_n \xrightarrow{P} \mu$ pro $n \rightarrow \infty$ (angl. nezávislé body kostkou)
 (angl. závislost i.i.d. = independent and identically distributed)
 písničková konvergence

neboli

$$\lim_{n \rightarrow \infty} P(|\bar{X}_n - \mu| < \varepsilon) = 1 \text{ pro lib. } \varepsilon > 0$$

(též se nazývá slabá konvergence náhodných veličin)

silná verze: vlastnost písničkové konvergencie je o třetí jistou konvergenci

$$\bar{X}_n \xrightarrow{\text{a.s.}} \mu \text{ pro } n \rightarrow \infty \quad (\text{a.s.} = \text{almost surely})$$

neboli

$$P\left(\lim_{n \rightarrow \infty} \bar{X}_n = \mu\right) = 1$$

(též silná konvergence)

silná verze implikuje slabou verzi

střední hodnota funkce náhodné veličiny

- nechť $Y = f(X)$ je náhodná veličina, která je fórmou X , pak lze uhradit, že

$$E(Y) = E(f(X)) = \int f(x) g(x) dx \quad (= \sum_{i=1}^N f(x_i) p_i \text{ pro diskr. náh. veličinu})$$

a obecně $E(f(x)) \neq f(E(x))$

Rovnoměrné rozdělení (uniform distribution) na intervalu (a, b)

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

$$E(X) = \frac{a+b}{2} \quad D(X) = \sigma_X^2 = \frac{(b-a)^2}{12} \quad F(x) = \frac{x-a}{b-a} \quad \text{pro } x \in (a, b)$$

. toto rozdělení má např. základní funkci chýba

Normalní rozdělení pravděpodobnosti $N(\mu, \sigma^2)$

$$g(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-(x-\mu)^2/2\sigma^2}, \quad E(X) = \mu, \quad D(X) = \sigma^2$$

distribuci fce

$$F(x) = \int_{-\infty}^x g(t) dt = \frac{1}{2} \left[1 + \operatorname{Erf}\left(\frac{x-\mu}{\sqrt{2}\sigma}\right) \right]$$

$$\text{kde } \operatorname{Erf}(z) = \frac{2}{\sqrt{\pi}} \int_0^z e^{-t^2} dt$$

je tav. error funkce

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

$$\operatorname{Erf}(-z) = -\operatorname{Erf}(z)$$

Pravidlo 3 sigma

$$P[\mu - 3\sigma \leq X \leq \mu + 3\sigma] = \frac{1}{2} \left[\operatorname{Erf}\left(\frac{3}{\sqrt{2}}\right) - \operatorname{Erf}\left(-\frac{3}{\sqrt{2}}\right) \right] = \operatorname{Erf}\left(\frac{3}{\sqrt{2}}\right) = 0,9973$$

tzn. že náhodné měření teče vždy leží v int. $(\mu - 3\sigma, \mu + 3\sigma)$

Pravděpodobná chyba náhodné veličiny X

- když jedno měření, pak s velkou pravd. bude v int. $(\mu - 3\sigma, \mu + 3\sigma)$

a absolutní chyba od střední hodnoty μ bude rádu $r = 0,6745\sigma$

což je tislo, pro které $P[\mu - r \leq X \leq \mu + r] = 0,5$

neboli pravd. že měření leží v int. $(\mu - r, \mu + r)$ je $1/2$

číslo $r = 0,6745\sigma$ se nazývá pravděpodobná chyba.

Centrální limitní věta (základní verze)

• uvažuje nás nezávislých náhodných veličin X_1, \dots, X_n , které mají stejný

rozdělení pravd., tj. jejich střední hodnota $\mathbb{E}(X_i) = \mu$ a rozptyl $D(X_i) = \sigma^2$ jsou stejné

• označme jejich součet

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

a tedy $E(S_n) = nm$ a $D(S_n) = n\sigma^2$

• uvažuje dle normalní rozdělení $N(\mu, \sigma^2)$ kde $\mu = nm$ a $\sigma^2 = n\sigma^2$
s hustotou pravd. $g_n(x)$

Pak centrální limitní věta říká, že

$$P[S_1 \leq S_n \leq S_2] = \int_{S_1}^{S_2} g_n(x) dx \quad \text{pro lib. } S_1 \text{ a } S_2 \text{ a i všechna velikosti}$$

rozdělení, tj. součet S_n velkého množství nezávislých náhodných prošených je přibližně normální

• ve skutečnosti lze tento tvrzení dokázat za mnohem slabších podmínek

- podmínka X_1, \dots, X_n nemusí být nezávislé a stejného rozdělení

- důležité je, že každá pravd. X_i nesmí být dležitou vlivem chybou

- to je důvod, proč mnoho rozdělení v přírodě je normálních - vliv mnoha náhodných faktorů

- to, že $\sigma = \sqrt{b}$ je dležité pro odhad chyby veličiny S_n
 a ~~také~~ též pro odhad chyby metody Monte Carlo, která obvykle
 počítá ^{násobkem} veličiny typu ~~X~~ ^{předpokládá} ~~veličin~~ X_i s násobnou postupní rozdělení

Odhad chyby metody MC

- nechť chceme spočítat hodnotu m neznámé veličiny \sim nechť máme
 náhodou ~~veličinu~~ X , pro kterou $E(X) = m$ a $D(X) = b^2$
- pokud vezmeme n nezávislých náh. veličin X_1, X_2, \dots, X_n , pak
 z centrální limítové věty víme, že $S_n = X_1 + \dots + X_n$ bude přibližně normální
 a tedy $P[m - 3b\sqrt{n} \leq S_n \leq m + 3b\sqrt{n}] \approx 0,9973$
- vydělení N , tj. spočítání průměru veličin X_i , který bude tedy
 normální rozdělení, dostaneme

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

což píšeme jako

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

- základní vztah pro odhad chyby metody MC a vlastnosti jejího
 použití, nejdeme-li veličinu X s rozdělením takovým, že $E(X) = m$ -
 je hledaná veličina, pak vezmeme n náhodně vybraných X_i a vidíme,
 že jejich průměr se bude lišit od m o maximálně $\frac{3b}{\sqrt{n}}$ s pravděpodobností 0,9973
- zvýšujeme-li n , pak tento "odhad chyby" klesá jeho $\frac{1}{\sqrt{n}}$
- nejdle o ~~omezení~~ omezení chyby shora, chyba může být ve skutečnosti
 větší, ale pravděpodobnost toho je velmi malá

Generitory (pseudo) náhodých čísel (random numbers)

- deterministické programy generující posloupnost čísel, které splňují jisté kritéria (testy) náhodnosti
- při stejných počítačích generují tedy náhodná čísla
 - poč. pod. = random seed (náhodné "seinko")
- vzhledem ke konečné aritmetice počítaců ~~je~~ a deterministickou charakterem nejde o náhodná čísla, ale o pseudonáhodná
- většinou generována jako posloupnost čísel $\{x_0, x_1, x_2, \dots\}$ → vlna periodicitu, kvůli konci aritmetice \Rightarrow perioda generatoru = nejmenší k takové, že $x_i = x_{i+k}$ pro každou

Základní generitory

- lineární kongruentní generátor (LCG) - velmi rychlý algoritmus
 - maximální (optimální) perioda = větší, než menší

speciální případ - multiplicativní LCG, když $c=0$ (navrhl D.H. Lehmer)

byl velmi často používán v historii, ale má často zásadní nedostatky pro aplikace ve více dimenzích, neboť matici $(x_i, x_{i+1}, \dots, x_{i+n-1})$ se nachází na ~~je~~ relativně malém počtu $(n-1)$ -rozm. nadplochách

Př. Nejznámější generátor RANDU

$$a = 65539, c = 0, m = 2^{31} \text{ splňuje rekur. vztah } x_{i+2} = (2^{16} + 3)x_{i+1} \bmod 2^{31}$$

$$x_{i+2} = (2^{32} + 6 \cdot 2^{16} + 9)x_i \bmod 2^{31} = (6x_{i+1} - 9x_i) \bmod 2^{31}$$

a lze ukázat, že k trojice bodů se nachází na 15 paralelních rovinách

Marsaglia: Random Numbers Fall Mainly in the Planes, PNAS 61 (1968) 25

Teoretyčtí pro MLGG: Pokud c_1, \dots, c_n jsou přirozená čísla taková, že

$$c_1 + c_2 a + c_3 a^2 + \dots + c_n a^{n-1} \equiv 0 \pmod{m}$$

pak k třem body $P_1 = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n), P_2 = (\mathbf{y}_1, \dots, \mathbf{y}_{n+1}), \dots$ leží v jedné z paralelních nadploch

$$c_1 \mathbf{x}_1 + c_2 \mathbf{x}_2 + \dots + c_n \mathbf{x}_n = 0, \pm 1, \pm 2, \dots$$

Navíc je nejvýše $|c_1| + |c_2| + \dots + |c_n|$ těchto rovin protká krychli

$0 < x_1 < 1, \dots, 0 < x_n < 1$ a vždy lze vybrat taková c_1, \dots, c_n , že

tři body budou vzdálené než $(n!m)^{1/n}$ nadplochách.

Integrace pomocí metody Monte Carlo

- obecně má tato metoda velký výhodu – především pro vícerozměrné integrály neboť její chyba nezávisí na dimenzi, ale pouze na počtu pozitivních bodů $\mathcal{O}(\frac{1}{\sqrt{n}})$
 - pro $n \leq 4$ je obvykle mnohem přesnější použít různé kvadratury

- pro jednoduchost si ilustruje metodu na jednoroz. příklad.

Méuje $I = \int_0^1 f(x) dx$

Wále-li weze a, b , pozijene jednoducle, lineární naporadni,

$$\int_a^b f(x) dx = \int_0^{(b-a)} \tilde{f}(y) dy$$

$$\tilde{f}(y) = f[(b-a)y - a]$$

a urazuje o něm jeho

a primitiva $f(x)$ no intervalo $(0, 1)$

o průměru $f(x)$ na intervalu $(0,1)$
 Tento průměr lze approximovat pomocí $I = \frac{1}{N} \sum_{i=1}^N f(x_i)$, kde x_i jsou
 „rovnoramenné“ rozložené v int. $(0,1)$, v případě - tedy MC
 uvažuje x_i jako vhodně vybrané se stejnou pravděpodobností
 kdekoliv v intervalu $(0,1)$.

, $f(x_i)$ je tedy náhodná veličina ~~j~~ s jistým rozdělením

její střední hodnota je $I = \int_0^1 f(x) dx$ a nechť je rovná \bar{f}

- ſf je ~~ti~~ - ^{wensi}, dan je f(x) bladsi' (pro konstru tv je ſf nula)
(speciat)

• En følgende MC udhældes + præs.

$$\sigma_f^2 \approx \langle f^2 \rangle - \langle f \rangle^2 = \frac{1}{N} \sum_{i=1}^N f(x_i)^2 - \left[\frac{1}{N} \sum_{i=1}^N f(x_i) \right]^2$$

• použití - centrální limity věty dostaneme pro odhad cly by

$$(\text{ro} \neq \text{pt}) \mid I) \quad b_H^* \approx \frac{54}{12}$$

- vidíme, že clyba tleská jde o $N^{-1/2}$ (tedy ne moc rychle)

paravanteli to slíkobéžníkový pravidlo ~~$\sigma(n) = \sigma(n) + \sigma(n)$~~
Nelkoj pojet bude

chyba v objevu
n obecně $\sigma(h^{d+2})$
takofor objev je n^d
a h $n^{\frac{1}{d}}$
takže chybce celková

$$\text{dizenz} \quad \text{lichobereink} \quad \sigma(N^{-2}) \approx \sigma(N^{-2}) \quad n = N$$

$$\sigma(n^2) \sim \sigma(N^2) \quad n = N$$

$$\begin{array}{ll} 3 & \mathcal{O}(n^{-2}) \sim \mathcal{O}(N^{-2/3}) \quad n^3 = N \\ 4 & -(-2) \quad \mathcal{O}(N^{-1/2}) \quad n^4 = N \end{array}$$

$\Rightarrow 4 \quad \delta(n^2) \sim \delta(N^2) \quad n \rightarrow N$

$$J^c \propto n^d \sigma(n^{d-2}) \sim \sigma(n^2)$$

pro 4D je presnost MC srovnatelná s lichoběžníkem - pravidlo

aršík obecne pro hladke' fe se pouzívají mrohe - presnejši
aršík obecne pro hladke' fe se pouzívají mrohe - presnejši
aršík obecne pro hladke' fe se pouzívají mrohe - presnejši

$$\approx n = N^{1/d}$$

$$\text{order } \tilde{\mathcal{O}}(\tilde{N}^{-2/d})$$

- avšak MC má výhodu, relativně jednoduché práce se složitými akcemi ~~oblasti~~^{integrací}

N celkový počet bodů
srdru a tedy
 $\approx \frac{1}{n} \sum f(x_i)$

grid a tedy
point valence $f(\vec{x})$

n počet bodů k výhry

- ze vztahu $\sigma_I \sim \frac{\sigma_f}{\sqrt{N}}$ je dalek patrné, že cílba MC integrace bude mít pokud σ_f bude malá, tj. pokud $f(x)$ se bude blížit konstantě \rightarrow možné zpřesnit integrace pouze výběrem $w(x)$, která je kladná a $\int dx w(x) = 1$

pak $I = \int_0^1 dx w(x) \frac{f(x)}{w(x)}$ a přechode k proměnné $y(x) = \int_0^x dx' w(x')$
 $\frac{dy}{dx} = w(x)$, $y(0) = 0$
 $y(1) = 1$

dostane se $I = \int_0^1 dy \frac{f(x(y))}{w(x(y))} = \int_0^1 dy g(y)$

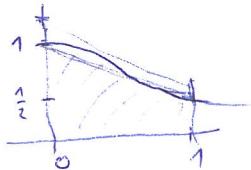
a dále postupuje stejně jako dříve

- problém je s inverzí fce $y(x)$, když se vám podaří najít vhodné $w(x)$

Pr. $f(x) = \frac{1}{1+x^2}$

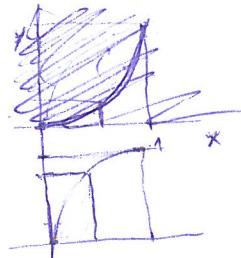
lze užít

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



pak $y(x) = \frac{1}{3}x(4-x)$

a $x(y) = 2\sqrt{4-3y}$



zlepšení přesnosti očekád?

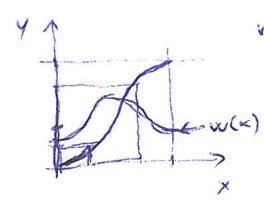
- protože najít $x(y)$ je často náročné a ve vícerozměrném případě

když máme Jacobian $\left| \frac{\partial y}{\partial x} \right| = w(x)$ prakticky nejdíme

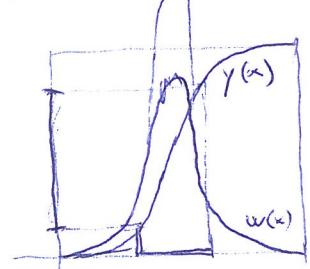
je dobré se na vztah $dy = w(x) dx$ podívat jako na zákon rovnoramenného rozdělení $g(y)=1$ a na rozdělení $w(x)$

vidíme, že je-li y rovnoramenně rozdělena na $(0,1)$, pak x bude

rozděleno



podle $w(x)$ a tedy budou se brát x rozděleno podle $w(x)$, kde $w(x)$ má např. peak převratně tan, kde $w(x)$ má např. peak neboť tan $y(x)$ rychle roste



- místo toho alychom provedli zákon pročinných

můžeme stále používat x , ale místo rovnoramenného rozdělení pro x použít $w(x)$

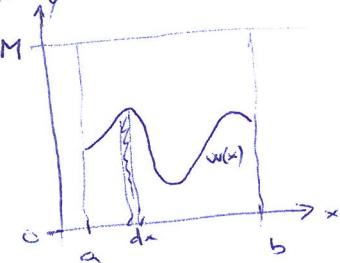
\rightarrow problém generování vhodné veličiny s daným rozdělením pští

Generování náhodných pravěkých s danou rozdělovací fci'

- jak z rovnoměrného rozdělení podělit jiné, anž bychom invertovali vztah typu $\int_w(x) dx = y(x)$?
- existují speciální postupy pro určité rozdělení; pro obecné ~~postupy~~ rozdělení lze použít von Neumannova metodu či Metropolisův - Hastingsův algoritmus

Von Neumannova metoda

- jde o jednoduchou metodu, kdy generuje řady dvojic náhodných čísel s rovnoměrným rozdělením a ~~je~~ rozložené dle $w(x)$, kde je posetlána, až nikoli



1) Z náhodných čísla ξ_i, η_i náhodně je na interval (a, b) a $(0, M)$, kde M je konstanta pro interval $w(x) < M$ pro $x \in (a, b)$

$$\text{dostane se } x_i = a + \xi_i(b-a), \quad y_i = M \eta_i$$

2) pokud $y_i \leq w(x_i)$, pak x_i použije - e
pokud $y_i > w(x_i)$, pak x_i zchodi - e

protože y_i je generována s rovnoměrným rozdělením, bude pořád $y_i \leq w(x_i)$, pak x_i použije - e
přitom, že přijaté hodnota bude v ~~je~~ intervalu (x_i, x_i+dx) ,
uveruji $w(x) dx$, neboť pak, že hodnota y_i je akceptována je $w(x_i)/M$
toto je za x_i upravené rozdělení z (a, b)

- či - je M menší, tím méně hodnot zahajuje - a celý proces je efektivnejší

Generování normálního rozdělení

- budu lze užít centrální limitní věty a počítat součty rovnoměrně rozdělených náhodných veličin
- ⇒ aproximace norm. rozdělení

• nebo trikem: využij - e Gaussovo rozdělení ve 2D (normované)

$$\text{fj. } e^{-\frac{1}{2}(x_1^2+x_2^2)} dx_1 dx_2$$

(x_1 a x_2 jsou 2 náhodné veličiny s norm. rozdělením)

$$\text{v polárních souř. máme } r = \sqrt{x_1^2 + x_2^2}, \quad \theta = \arctg \frac{x_2}{x_1} \Rightarrow e^{-\frac{1}{2}r^2} r dr d\theta \text{ a pro } u = \frac{1}{2}r^2$$

$$\text{dostaneme } e^{-u} du d\theta \text{ pak tedy vysílá } u \in (0, \infty) \text{ s rozdělením } e^{-u}$$

(např. pomocí $y = 1 - e^{-u} \Rightarrow u = -\ln(1-y)$)

a $\theta \in (0, 2\pi)$ s rovnoměrným rozdělením

$$\text{pak } x_1 = \sqrt{2u} \cos \theta \text{ a } x_2 = \sqrt{2u} \sin \theta \text{ bude s normálním rozdělením } N(0, 1)$$

• chce-li norm. rozdělení $N(\mu, \sigma^2)$, pak provedeme ještě transformaci

$$x'_i = \mu + \sigma x_i$$

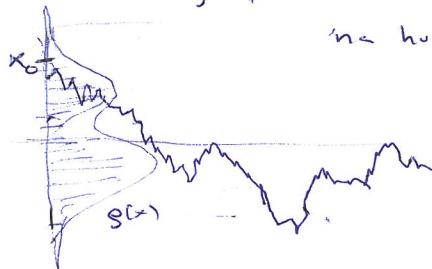
Metropolis-Hastingsův algoritmus

• základní myšlenka:



• jít "nahodou" procházkou v prostoru v závislosti

na hustotu pravd.



necht je x_k v nejčetnějším

učiněno nahodou krok o $\delta x_k = \{k\}$ (je zadáný parametr)

a tento krok přijme, pokud

$$g(x_k + \delta x_k) \geq g(x_k)$$

pokud $g(x_k + \delta x_k) < g(x_k)$, pak

vygeneruje ještě jedno nahod. číslo $M \in (0, 1)$ a krok pěstuje, pokud

$$g(x_k + \delta x_k) / g(x_k) \geq M$$

jinak krok neuděláme a $x_{k+1} = x_k$

• v 1D dostaneme algoritmus $r(:) = \text{random}(:)$

$$x_{\text{trial}}(:) = x(:) + \delta(2r(:) - 1) \quad r \in [0, 1] \quad \text{pohyb}$$

$$\text{ratio} = g(x_{\text{trial}}) / g(x(:)) \quad \text{toto si lze paravat}$$

z minulého kroku

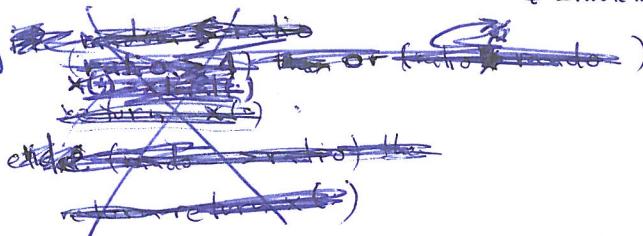
if (ratio ≥ 1)

or (ratio > random)

then

$x(:) = x_{\text{trial}}(:)$

return $x(:)$



• Proč to funguje? v lib. dvojk. prochážení tento algoritmus generuje body rozložené podle $g(x)$

• označme $N_n(x)$ hustotu nahod. chodců startujících v různých bodech nestářejších po n krocích

• pak počet chodců jdoucích z x do y v následujícím kroku je

$$\Delta N(x) = N_n(x) P(x \rightarrow y) - N_n(y) P(y \rightarrow x) = \\ = N_n(y) P(x \rightarrow y) \left[\frac{N_n(x)}{N_n(y)} - \frac{P(y \rightarrow x)}{P(x \rightarrow y)} \right]$$

kde $P(x \rightarrow y)$ je pravděpodobnost, že chodec přejde z x do y

• rovnováha nestáří pro $\frac{N_n(x)}{N_n(y)} = \frac{P(x \rightarrow y)}{P(y \rightarrow x)}$ a lze ukázat,

že pro velká n je $N_n(x) \rightarrow N_e(x)$, což je rovnováha ~~nestáří~~ rozdělení chodců v x

• zbyvalo ukázat, že $N_e(x) \sim g(x)$

• $P(x \rightarrow y)$ lze ujmout jako $P(x \rightarrow y) = T(x \rightarrow y) A(x \rightarrow y)$

• kde $T(x \rightarrow y)$ je hustota nahod. výběru chodců z x do y
a $A(x \rightarrow y)$ je hustota přijmutí tohoto kroku

• a pokud bude $\frac{g(x)}{g(y)} = \frac{T(y \rightarrow x)}{T(x \rightarrow y)} A(y \rightarrow x)$ pak $N_e(x)$ bude ustálit u $\sim g(x)$

• to nastave např. pokud y lze dosíhnout už jedinou kroku, tj. $\mathcal{G} = W$
 y leží v $x + \delta \mathbb{S}$, protože pak $T(x \rightarrow y) = T(y \rightarrow x)$

a navíc v některém algoritmu ~~je~~ pro $\mathcal{G}(x) > \mathcal{G}(y)$ bude $A(y \rightarrow x) = 1$
 a pro $\mathcal{G}(y) > \mathcal{G}(x)$ bude $A(x \rightarrow y) = 1$
 $A(y \rightarrow x) = \frac{\mathcal{G}(x)}{\mathcal{G}(y)}$

a tedy bude v každém případě

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