
Monte Carlo metody

**© 1996-2001 Josef Pelikán
KSVI MFF UK Praha**

e-mail: Josef.Pelikan@mff.cuni.cz
WWW: <http://cgg.ms.mff.cuni.cz/~pepca/>

Monte Carlo integrace

Odhadovaný integrál:

$$I = \int_0^1 f(x) dx$$

Předpoklad: $f(x) \in L^2(0,1)$


Je-li ξ náhodné číslo s distribucí $R(0,1)$, pak $f(\xi)$ je tzv. **primární odhad** integrálu:

$$\langle I \rangle_{\text{prim}} = f(\xi)$$

Odhad je **nestranný**, neboť:

$$E(\langle I \rangle_{\text{prim}}) = \int_0^1 f(x) dx = I$$

Primární odhad urč. integrálu



Rozptyl odhadu


Měřítkem kvality odhadu je jeho **rozptyl** (nebo standardní odchylka):

$$\mathbf{V}(\langle \mathbf{l} \rangle_{\text{prim}}) = \sigma_{\text{prim}}^2 = \int_0^1 |f(x) - l|^2 dx = \int_0^1 f(x)^2 dx - l^2$$

(pro nestranný odhad)

Při výpočtu **jediného vzorku** je rozptyl výsledku příliš velký!

Sekundární odhad urč. integrálu



Sekundární odhad

Rozložení integrálu na součet **N členů**:

$$I = \int_0^1 f(x) dx = \sum_{i=1}^N \int_0^1 \frac{f(x)}{N} dx = \sum_{i=1}^N I_i$$

Sekundární odhad integrálu:

$$\underline{\langle I \rangle_{sec}} = \sum_{i=1}^N \langle I_i \rangle_{prim} = \frac{1}{N} \sum_{i=1}^N f(\xi_i)$$

Sekundární odhad je také **nestranný**.

Rozptyl sekundárního odhadu

$$\sigma_{\text{sec}}^2 = \int_0^1 \dots \int_0^1 \left[\frac{1}{N} \sum_{i=1}^N f(x_i) \right]^2 dx_1 \dots dx_N - I^2 =$$

$$= \frac{1}{N} \int_0^1 f^2(x) dx - \frac{1}{N} I^2 =$$


$$= \frac{\sigma_{\text{prim}}^2}{N}$$

... std. chyba je \sqrt{N} -krát menší!
(konvergence $1/\sqrt{N}$)

Vzorkování po částech

- ◆ při výběru množiny nezávislých vzorků se stejnou hustotou pravděpodobnosti dochází ke **shlukování**
 - zbytečně velký rozptyl odhadu
- ➔ **vzorkování po částech (“stratified sampling”)**
 - potlačuje shlukování
 - redukuje rozptyl odhadu
- ➔ interval se rozdělí na části, které se odhadují **samostatně**

Vzorkování po částech



Vzorkování po částech

Rozdělení intervalu **(0,1)** na **N** částí **A_i**:

$$I = \int_0^1 f(x) dx = \sum_{i=1}^N \int_{A_i} f(x) dx = \sum_{i=1}^N I_i$$

Odhad integrálu:

$$\underline{\langle I \rangle_{\text{strat}}} = \sum_{i=1}^N \langle I_i \rangle_{\text{prim}} = \frac{1}{N} \sum_{i=1}^N f(\xi_i), \quad f(\xi_i) \in A_i$$

Rozptyl vzorkování po částech

$$\sigma_{\text{strat}}^2 = \sum_{i=1}^N \left[\int_{A_i} \left[\frac{f(x_i)}{N} \right]^2 N dx_i - l_i^2 \right] = \\ = \frac{1}{N} \int_0^1 f^2(x) dx - \sum_{i=1}^N l_i^2 \leq \sigma_{\text{sec}}^2$$

... rozptyl nemůže být větší než
u sekundárního odhadu!


Rozklad intervalu na části

- ◆ uniformní rozklad intervalu **(0,1)**
 - přirozená metoda pro zcela neznámou funkci **f**
- ◆ známe-li alespoň přibližně **průběh funkce f**, snažíme se o takový rozklad, aby byl rozptyl funkce na subintervalech co nejmenší
- ◆ rozklad **d-rozměrného intervalu** vede na **N^d** výpočtů
 - úspornější metodou je vzorkování “**N věží**”

Vzorkování podle důležitosti

- ◆ některé části vzorkovaného intervalu jsou **důležitější**, protože zde má **f** větší hodnotu
 - vzorky z těchto oblastí mají větší vliv na výsledek
- ➔ **vzorkování podle důležitosti** (“importance sampling”) umisťuje vzorky přednostně do takových oblastí
 - vzorkování je formálně řízeno funkcí **p(x)** ...
hustotou pravděpodobnosti na daném intervalu
- ➔ **menší rozptyl** při zachování nestrannosti

Vzorkování podle důležitosti



Vzorkování podle důležitosti

Úprava odhadovaného integrálu:

$$I = \int_0^1 f(x) dx = \int_0^1 \frac{f(x)}{p(x)} p(x) dx$$

Má-li náhodná proměnná ξ rozdělení s hustotou $p(x)$, odhadujeme integrál I výrazem:

$$\langle I \rangle_{\text{imp}} = \frac{f(\xi)}{p(\xi)}$$

(tento odhad je **nestranný**)

Rozptyl vzorkování podle důlež.

$$\underline{\sigma_{\text{imp}}^2} = \int_0^1 \left[\frac{\mathbf{f}(\mathbf{x})}{\mathbf{p}(\mathbf{x})} \right]^2 \mathbf{p}(\mathbf{x}) \, d\mathbf{x} - \mathbf{l}^2 =$$
$$= \int_0^1 \frac{\mathbf{f}^2(\mathbf{x})}{\mathbf{p}(\mathbf{x})} \, d\mathbf{x} - \mathbf{l}^2$$

Pokud se průběh hustoty **p(x)** podobá integrované funkci **f(x)**, odhadujeme integrál funkce, která má **menší rozptyl** než **f(x)**.

Vlastnosti hustoty $p(x)$

- ◆ $p(x) \geq 0$ a $p(x) > 0$ tam, kde $f(x) \neq 0$
- ◆ $\int p(x) dx = 1$
- ◆ lze efektivně generovat vzorky s danou hustotou pravděpodobnosti
 - lze spočítat příslušnou distribuční funkci $P(x)$ a zinvertovat ji ($P^{-1}(x)$)

$$\underline{P(x)} = \int_0^x p(t) dt$$

Praktická implementace

Místo přímého výběru náhodné proměnné s hustotou pravděpodobnosti $p(x)$ bereme τ s **rovnoměrným rozdělením** pravděpodobnosti a transformujeme ji:


$$\xi = \underline{\mathbf{P}^{-1}(\tau)}$$

Odhad má tedy tvar:

$$\langle I \rangle_{\text{imp}} = \frac{f(P^{-1}(\tau))}{p(P^{-1}(\tau))}$$

$$I = \int_0^1 f(x) dx = \int_0^1 f(P^{-1}(t)) \frac{dP^{-1}(t)}{dt} dt = \int_0^1 \frac{f(P^{-1}(t))}{p(P^{-1}(t))} dt$$

Kombinované odhady



Kombinace několika odhadů

Předpokládáme n náhodných proměnných ξ_1, \dots, ξ_n s hustotami pravděpodobnosti $p_1(x), \dots, p_n(x)$.

Kombinovaný odhad integrálu bude mít tvar:

$$\langle I \rangle_{\text{comb}} = \sum_{i=1}^n w_i(\xi_i) \frac{f(\xi_i)}{p_i(\xi_i)}$$

kde $w_i(x)$ jsou nezáporné váhové funkce.

Nestrannost kombin. odhadu

$$\begin{aligned} \underline{\mathbf{E}(\langle I \rangle_{\text{comb}})} &= \sum_{i=1}^n \int_0^1 \left[w_i(x_i) \frac{f(x_i)}{p_i(x_i)} \right] p_i(x_i) dx_i = \\ &= \int_0^1 \left[\sum_{i=1}^n w_i(x) \right] f(x) dx \equiv \int_0^1 f(x) dx \end{aligned}$$

Podmínka pro
váhové funkce:

$$\boxed{\forall x: \sum_{i=1}^n w_i(x) = 1}$$

Rozptyl kombinovaného odhadu

$$\sigma_{\text{comb}}^2 = \sum_{i=1}^n \left\{ \int_0^1 \left[w_i(x_i) \frac{f(x_i)}{p_i(x_i)} \right]^2 p_i(x_i) dx_i - \left[\int_0^1 w_i(x_i) \frac{f(x_i)}{p_i(x_i)} p_i(x_i) dx_i \right]^2 \right\}^2 = \\ = \int_0^1 \left[\sum_{i=1}^n \frac{w_i^2(x)}{p_i(x)} \right] f(x) dx - \sum_{i=1}^n \left[\int_0^1 w_i(x) f(x) dx \right]^2$$

Aritmetický průměr, maximum

$$w_i(x) = \frac{1}{n}$$

$$\langle I \rangle_{\text{average}} = \frac{1}{n} \sum_{i=1}^n \frac{f(\xi_i)}{p_i(\xi_i)}$$

$$w_i(x) = \begin{cases} 1 & \text{pro } p_i(x) = \max_j \{ p_j(x) \} \\ 0 & \text{jinde} \end{cases}$$

$$\langle I \rangle_{\text{max}} = \sum_{i=1}^n (p_i(\xi_i) = \max_j \{ p_j(\xi_i) \}) ? \frac{f(\xi_i)}{p_i(\xi_i)} : 0$$

Vyrovnána heuristika

$$w_i(x) = \frac{p_i(x)}{\sum_{j=1}^n p_j(x)}$$

$$\langle I \rangle_{\text{bal}} = \sum_{i=1}^n \frac{f(\xi_i)}{\sum_{j=1}^n p_j(\xi_i)}$$

$$\sigma_{\text{bal}}^2 = \int_0^1 \frac{f^2(x)}{\sum_{i=1}^n p_i(x)} dx - \sum_{i=1}^n \left[\int_0^1 \frac{p_i(x)}{\sum_{j=1}^n p_j(x)} f(x) dx \right]^2$$

$$\sigma_{\text{comb}}^2 \geq \sigma_{\text{bal}}^2 - \left(1 - \frac{1}{n}\right) \cdot I^2$$

Mocninná heuristika

Zobecnění: $w_i(x) = \frac{p_i^\beta(x)}{\sum_{j=1}^n p_j^\beta(x)}$

$$\langle I \rangle_{\text{power}} = \sum_{i=1}^n \frac{p_i^{\beta-1}(\xi_i)}{\sum_{j=1}^n p_j^\beta(\xi_i)} f(\xi_i)$$

$\beta = 1$.. vyrovnaná, $\beta = \infty$.. maximální heuristika

Transformace integrandu


Interpretace kombinačního odhadu jako
transformace integrované funkce:

$$I = \int_0^1 f(x) dx = \sum_{i=1}^n \int_0^1 w_i(x) \cdot f(x) dx$$


Kombinace odhadů podle důležitosti:

$$I = \sum_{i=1}^n \int_0^1 \frac{w_i(P_i^{-1}(t))}{p_i(P_i^{-1}(t))} f(P_i^{-1}(t)) dt$$

Jeden člen kombin. odhadu




Aritmetický průměr




Maximum

$$[\mathbf{p}_1(\mathbf{t}) > \mathbf{p}_2(\mathbf{t}) ? 1 : 0] \frac{\mathbf{f}\left(\mathbf{P}_1^{-1}(\mathbf{t})\right)}{\mathbf{p}_1\left(\mathbf{P}_1^{-1}(\mathbf{t})\right)}$$




Vyrovnána heuristika



Mocninná heuristika pro $\beta=2$

$$\frac{p_1(P_1^{-1}(t)) \cdot f(P_1^{-1}(t))}{p_1^2(P_1^{-1}(t)) + p_2^2(P_1^{-1}(t))}$$




Řídící funkce

Funkce $\mathbf{g(x)}$, která **aproxi muje integrand a dokážeme ji analyticky zintegrovat**:

$$\begin{aligned} \mathbf{I} &= \int_0^1 \mathbf{f(x) dx} = \int_0^1 [\mathbf{f(x)} - \mathbf{g(x)}] \mathbf{dx} + \int_0^1 \mathbf{g(x) dx} = \\ &= \int_0^1 [\mathbf{f(x)} - \mathbf{g(x)}] \mathbf{dx} + \underline{\mathbf{J}} = \int_0^1 [\mathbf{f(x)} - \mathbf{g(x)} + \mathbf{J}] \mathbf{dx} \end{aligned}$$

Nestranný odhad: $\langle \mathbf{I} \rangle_{\text{con}} = \mathbf{f(\xi)} - \mathbf{g(\xi)} + \mathbf{J}$


Transformace řídící funkcí



Řešení integrálních rovnic

Fredholmova integrální rovnice druhého typu:

$$f(x) = g(x) + \int_0^1 K(x, y) \cdot f(y) dy$$



- ➔ metody konečných prvků (výpočet celé funkce)
 - ➔ metody Monte Carlo (lokální výpočet)

Rekurzivní Monte Carlo odhad

Pravou stranu rovnice odhaduji stochasticky
s řídícími hustotami pravděpodobnosti $p_i(x)$:

$$\begin{aligned}\langle f(x) \rangle_r &= g(x) + \frac{K(x, \xi_1)}{p_1(\xi_1)} \cdot \langle f(\xi_1) \rangle_r = \\ &= g(x) + \frac{K(x, \xi_1)}{p_1(\xi_1)} \cdot \left[g(\xi_1) + \frac{K(\xi_1, \xi_2)}{p_2(\xi_2)} \cdot \langle f(\xi_2) \rangle_r \right] \\ &= g(x) + \frac{K(x, \xi_1)}{p_1(\xi_1)} g(\xi_1) + \frac{K(x, \xi_1)}{p_1(\xi_1)} \frac{K(\xi_1, \xi_2)}{p_2(\xi_2)} g(\xi_2) + ..\end{aligned}$$

Rekurzivní Monte Carlo odhad

$$\langle f(x) \rangle_r = \sum_{i=0}^{\infty} \left[\prod_{j=1}^i \frac{K(\xi_{j-1}, \xi_j)}{p_j(\xi_j)} \right] g(\xi_i), \quad \xi_0 = x$$

$\{\xi_1, \xi_2, \xi_3, \dots\}$ se nazývá **Markovovský řetězec**,
jestliže pravděpodobnost $p_i(x)$ závisí pouze na ξ_{i-1}

Úspornější funkcionální zápis: $f = g + T f$

Řešení (Neumannova řada): $f = g + Tg + T^2g + \dots$

Ruská ruleta

- ◆ při odhadu **nekonečné Neumannovy řady** se může spočítat jen konečný částečný součet
 - pevně daná délka posloupnosti zavádí do odhadu **systematickou chybu**
- ➔ vhodnější je metoda náhodného ukončení výpočtu: tzv. **ruská ruleta**
 - odhad zůstává nestranný
- ➔ teoreticky se dá tento postup aplikovat i na výpočet jednotlivého integrálu

Ruská ruleta pro jeden integrál

Transformace integrálu:

$$I = \int_0^1 f(x) dx = \int_0^P \frac{1}{P} f\left(\frac{t}{P}\right) dt \quad 0 < P \leq 1$$

Nestranný odhad s jedním náhodným vzorkem:

$$\langle I \rangle_{\text{Russ}} = \begin{cases} \frac{1}{P} f\left(\frac{\xi}{P}\right) & \text{pro } \xi < P \\ 0 & \text{jinak} \end{cases}$$

Ruská ruleta pro integr. rovnice

$$\langle f(x) \rangle_{\text{Russ,r}} = \sum_{i=0}^k \left[\prod_{j=1}^i \frac{K(\xi_{j-1}, \xi_j)}{P_j \cdot p_j(\xi_j)} \right] g(\xi_i), \quad \xi_0 = x$$

$\{\xi_1, \xi_2, \dots, \xi_k\}$ je konečná náhodná procházka, protože odhad $\langle f(\xi_k) \rangle = 0$.

Každý vzorek ξ_i je vybíráno s pravděpodobností P_i a s hustotou rozdělení $p_i(x)$.

Pokud náhodná proměnná $\tau_{i+1} > P_{i+1}$, celý proces se zastaví; jinak se vygeneruje ξ_{i+1} (a přidá se další člen).

Volba pravděpodobností

Ve fyzikálních aplikacích je často: $\int_0^1 K(x, y) dy < 1$

Tehdy lze jádro K použít ke kostrukci tzv.
subkritického rozdělení pravděpodobnosti:

$$P_i = \int_0^1 K(\xi_{i-1}, y) dy, \quad p_i(x) = \frac{K(\xi_{i-1}, x)}{P_i}$$

Odhad pak bude mít tvar:

$$\langle f(x) \rangle_{\text{subcrit}} = \sum_{i=1}^k g(\xi_i)$$

Odhad příští události

Předchozí odhad mívá **velký rozptyl** (málo sčítanců je nenulových). Lepší výsledky dává metoda odhadující člen **$g(x)$** o jeden stupeň přesněji:

$$f(x) = g(x) + h(x)$$

$$h(x) = \int_0^1 K(x, y) \cdot f(y) dy =$$

$$= \int_0^1 K(x, y) \cdot g(y) dy + \int_0^1 K(x, y) \cdot h(y) dy$$

Odhad příští události

- ◆ první integrál se odhaduje za pomocí pravděpodobnosti s hustotou podobnou funkci $\mathbf{g}(\mathbf{x})$
 - náhodná proměnná ζ_i s hustotou $p_i(x)$
- ◆ druhý integrál se odhaduje pomocí subkritické hustoty pravděpodobnosti jádra \mathbf{K}
 - náhodná proměnná ξ_i s hustotou $\mathbf{K}(\xi_{i-1}, \mathbf{x})/P_i$

$$\langle h(x) \rangle_{\text{nextev}} = \frac{\mathbf{K}(x, \zeta_1) \mathbf{g}(\zeta_1)}{p_1(\zeta_1)} + \langle h(\xi_1) \rangle_{\text{nextev}}$$

Odhad příští události

Odhad funkce h :

$$\langle h(x) \rangle_{\text{nextev}} = \sum_{i=1}^k \frac{K(\xi_{i-1}, \zeta_i) g(\zeta_i)}{p_i(\zeta_i)}$$

Odhad integrální rovnice:

$$\langle f(x) \rangle_{\text{nextev}} = g(x) + \sum_{i=1}^k \frac{K(\xi_{i-1}, \zeta_i) g(\zeta_i)}{p_i(\zeta_i)}$$

Konec

Další informace:

- E. Lafourture: *Mathematical Models and Monte Carlo Algorithms for Physically Based Rendering*, PhD thesis, KU Leuven, 29-63
- M. Kalos, P. Whitlock: *Monte Carlo Methods*, John Wiley & Sons, 1986, 89-116
- A. Glassner: *Principles of Digital Image Synthesis*, Morgan Kaufmann, 1995, 840-864