

Monte Carlo metody

© 1996-2019 Josef Pelikán
CGG MFF UK Praha

pepca@cgg.mff.cuni.cz

<http://cgg.mff.cuni.cz/~pepca/>



Monte Carlo integrace

Odhadovaný integrál:

$$I = \int_0^1 f(\mathbf{x}) \, d\mathbf{x}$$

Předpoklad: $f(\mathbf{x}) \in L^2(0,1)$


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

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

Odhad je **nestranný**, neboť:

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

Primární odhad určitého integrálu





Rozptyl odhadu




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

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

(pro nestranný odhad)

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

Sekundární odhad integrálu





Sekundární odhad

Rozložení integrálu na součet **N členů**:

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

Sekundární odhad integrálu:

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

Sekundární odhad je také **nestranný**.



Rozptyl sekundárního odhadu

$$\underline{\sigma_{\text{sec}}^2} = \int_0^1 \cdots \int_0^1 \left[\frac{1}{N} \sum_{i=1}^N f(\mathbf{x}_i) \right]^2 d\mathbf{x}_1 \cdots d\mathbf{x}_N - I^2 =$$

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

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


... 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 :

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

Odhad integrálu:

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



Rozptyl vzorkování po částech

$$\begin{aligned} \underline{\sigma_{\text{strat}}^2} &= \sum_{i=1}^N \left[\int_{A_i} \left[\frac{f(\mathbf{x}_i)}{N} \right]^2 N d\mathbf{x}_i - I_i^2 \right] = \\ &= \frac{1}{N} \int_0^1 f^2(\mathbf{x}) d\mathbf{x} - \sum_{i=1}^N I_i^2 \leq \underline{\sigma_{\text{sec}}^2} \end{aligned}$$

... 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:

$$I = \int_0^1 f(\mathbf{x}) \, d\mathbf{x} = \int_0^1 \frac{f(\mathbf{x})}{p(\mathbf{x})} p(\mathbf{x}) \, d\mathbf{x}$$

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

$$\langle I \rangle_{\text{imp}} = \frac{f(\xi)}{p(\xi)} \quad (\text{tento odhad je **nestranný**})$$

Rozptyl vzorkování podle důležitosti

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

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



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 $\mathbf{p}(\mathbf{x})$ bereme τ s **rovnoměrným rozdělením** pravděpodobnosti a transformujeme ji:


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

Odhad má tedy tvar:

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

$$\mathbf{I} = \int_0^1 \mathbf{f}(\mathbf{x}) \, d\mathbf{x} = \int_0^1 \mathbf{f}(\mathbf{P}^{-1}(\mathbf{t})) \frac{d\mathbf{P}^{-1}(\mathbf{t})}{d\mathbf{t}} \, d\mathbf{t} = \int_0^1 \frac{\mathbf{f}(\mathbf{P}^{-1}(\mathbf{t}))}{\mathbf{p}(\mathbf{P}^{-1}(\mathbf{t}))} \, d\mathbf{t}$$

Kombinované odhady





Kombinace několika odhadů

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

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 $w_i(\mathbf{x})$ jsou nezáporné **váhové funkce**.

Nestrannost kombinovaného odhadu

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

Podmínka pro
váhové funkce:

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

Rozptyl kombinovaného odhadu



$$\begin{aligned} \underline{\sigma_{\text{comb}}^2} &= \sum_{i=1}^n \left\{ \int_0^1 \left[w_i(\mathbf{x}_i) \frac{f(\mathbf{x}_i)}{p_i(\mathbf{x}_i)} \right]^2 p_i(\mathbf{x}_i) d\mathbf{x}_i - \right. \\ &\quad \left. - \left[\int_0^1 w_i(\mathbf{x}_i) \frac{f(\mathbf{x}_i)}{p_i(\mathbf{x}_i)} p_i(\mathbf{x}_i) d\mathbf{x}_i \right]^2 \right\} = \\ &= \int_0^1 \left[\sum_{i=1}^n \frac{w_i^2(\mathbf{x})}{p_i(\mathbf{x})} \right] f(\mathbf{x}) d\mathbf{x} - \sum_{i=1}^n \left[\int_0^1 w_i(\mathbf{x}) f(\mathbf{x}) d\mathbf{x} \right]^2 \end{aligned}$$



Aritmetický průměr, maximum

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

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

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

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



Vyrovnaná heuristika

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

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

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

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



Mocninná heuristika

Zobecnění:
$$\mathbf{w}_i(\mathbf{x}) = \frac{\mathbf{p}_i^\beta(\mathbf{x})}{\sum_{j=1}^n \mathbf{p}_j^\beta(\mathbf{x})}$$

$$\langle \mathbf{l} \rangle_{\text{power}} = \sum_{i=1}^n \frac{\mathbf{p}_i^{\beta-1}(\xi_i)}{\sum_{j=1}^n \mathbf{p}_j^\beta(\xi_i)} \mathbf{f}(\xi_i)$$

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



Transformace integrandu


Interpretace kombinačního odhadu jako **transformace integrované funkce:**

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


Kombinace odhadů podle důležitosti:

$$I = \sum_{i=1}^n \int_0^1 \frac{w_i(\mathbf{P}_i^{-1}(\mathbf{t}))}{p_i(\mathbf{P}_i^{-1}(\mathbf{t}))} f(\mathbf{P}_i^{-1}(\mathbf{t})) \, d\mathbf{t}$$


Jeden člen kombinovaného odhadu




Aritmetický průměr



Maximum

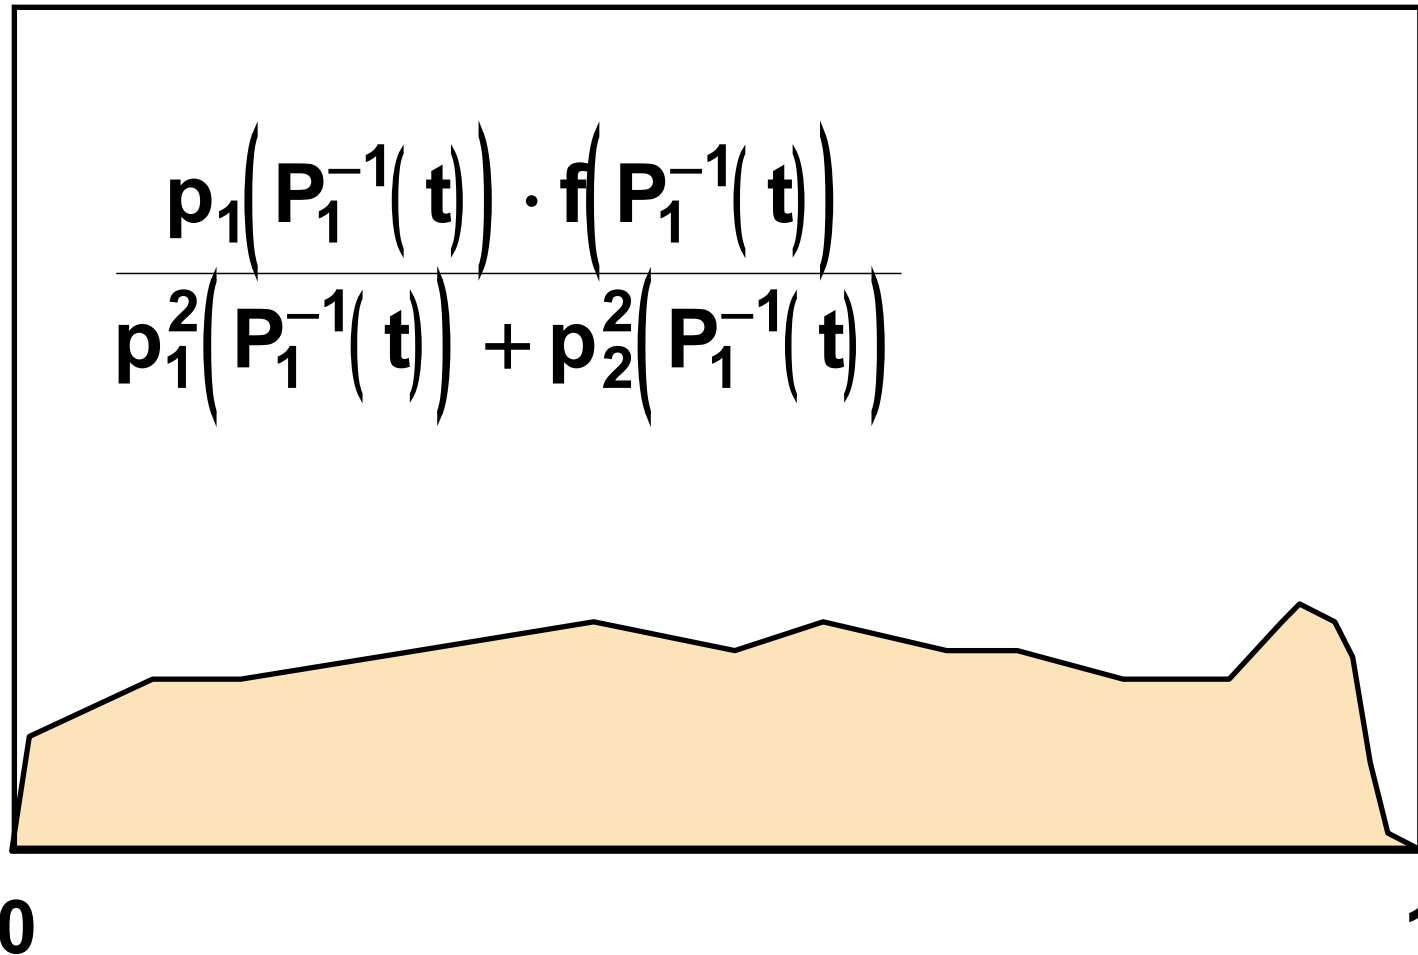


Vyrovnaná heuristika







Mocninná heuristika pro $\beta=2$



Příklad z renderingu




© 1995 Eric Veach, Leonidas J. Guibas






Příklad z renderingu




© 1995 Eric Veach, Leonidas J. Guibas






Příklad z renderingu



© 1995 Eric Veach, Leonidas J. Guibas

Power heuristics
 $\beta = 2$



Řídící funkce




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

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

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

Transformace řídicí funkcí



Řešení integrálních rovnic



Fredholmova integrální rovnice druhého typu:

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

neznámá

známé funkce

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

Rekurzivní Monte Carlo odhad



Pravou stranu rovnice odhadují stochasticky s řídicími hustotami pravděpodobnosti $p_i(\mathbf{x})$:

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



Rekurzivní Monte Carlo odhad

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

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

Úspornější funkcionální zápis: $\mathbf{f} = \mathbf{g} + \mathbf{T}\mathbf{f}$

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



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:

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

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 integrální rovnice

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

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

Každý vzorek ξ_i je vybírán s **pravděpodobností** \mathbf{P}_i a s hustotou (pdf) $\mathbf{p}_i(\mathbf{x})$.

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



Volba pravděpodobností

Ve fyzikálních aplikacích je často: $\int_0^1 \mathbf{K}(\mathbf{x}, \mathbf{y}) \, d\mathbf{y} < 1$


Tedy lze jádro \mathbf{K} použít ke konstrukci tzv. **subkritického rozdělení pravděpodobnosti**:

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

Odhad pak bude mít tvar:


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

Path Tracing – náhodná procházka





Path Tracing – šíření světla





Odhad příští události

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

$$\mathbf{f}(\mathbf{x}) = \mathbf{g}(\mathbf{x}) + \mathbf{h}(\mathbf{x})$$

$$\mathbf{h}(\mathbf{x}) = \int_0^1 \mathbf{K}(\mathbf{x}, \mathbf{y}) \cdot \mathbf{f}(\mathbf{y}) \, d\mathbf{y} =$$

$$= \int_0^1 \mathbf{K}(\mathbf{x}, \mathbf{y}) \cdot \mathbf{g}(\mathbf{y}) \, d\mathbf{y} + \int_0^1 \mathbf{K}(\mathbf{x}, \mathbf{y}) \cdot \mathbf{h}(\mathbf{y}) \, d\mathbf{y}$$



Odhad příští události

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

$$\langle \mathbf{h}(\mathbf{x}) \rangle_{\text{nextev}} = \frac{\mathbf{K}(\mathbf{x}, \zeta_1) \mathbf{g}(\zeta_1)}{\mathbf{p}_1(\zeta_1)} + \langle \mathbf{h}(\xi_1) \rangle_{\text{nextev}}$$



Odhad příští události

Odhad funkce h :


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

Odhad integrální rovnice:

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




NEE pro Path Tracing






Light Tracing – šíření světla






NEE pro Light Tracing



Obousměrný Path Tracing



Bidir PT – příklad



© 1995 Eric Veach,
Leonidas J. Guibas



Další informace:

- **E. Lafortune: *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**