

Počítačová grafika III – Monte Carlo integrování

Jaroslav Křivánek, MFF UK

Jaroslav.Krivanek@mff.cuni.cz

Rendering = Integrovaní funkcí

$$L_r(\mathbf{x}, \omega_o) = \int_{H(\mathbf{x})} L_i(\mathbf{x}, \omega_i) \cdot f_r(\mathbf{x}, \omega_i \rightarrow \omega_o) \cdot \cos \theta_i \, d\omega_i$$



- Problémy
 - ❑ Nespojitosť integrandu (viditelnost)
 - ❑ Téměř libovolné hodnoty integrandu (distribuce světla, BRDF)
 - ❑ Složitá geometrie

Historie Monte Carlo (MC)

- Vývoj atomové bomby, Los Alamos 1940, John von Neumann, Stanislav Ulam, Metropolis
- Rozvoj a aplikace metod od roku 1949

Metoda Monte Carlo

- Simuluje se mnoho případů daného děje, například:
 - Neurony – vznik, zánik, srážky s atomy vodíku
 - Úlohy hromadné obsluhy – chování počítačových sítí, dopravní situace
 - Sociologické a ekonomické modely – demografie, vývoj inflace, pojišťovnictví atd.

Num. integrování – Kvadrurní vzorce

- Obecný předpis v 1D:

$$\hat{I} = \sum_{i=1}^n w_i f(x_i)$$

- f integrand (tj. integrovaná funkce)
 n řád kvadratury (tj. počet vzorků integrandu)
 x_i uzlové body (tj. umístění vzorků v oboru integrálu)
 $f(x_i)$ vzorky integrandu
 w_i váhy

Num. integrování – Kvadrurní vzorce

- Kvadrurní pravidla se liší volbou uzlových bodů x_i a váhami w_i
 - Obdélníková metoda, Rovnoběžníková metoda, Simpsonova metoda, Gaussovská kvadratura, ...
- Vzorky na integračním oboru (tj. uzlové body) jsou rozmístěny deterministicky
 - Jednoznačně určeny kvadrurním pravidlem

Kvadrurní vzorce pro více dimenzí

- Obecný předpis pro více dimenzí:

$$\hat{I} = \sum_{i_1=1}^n \sum_{i_2=1}^n \dots \sum_{i_s=1}^n w_{i_1} w_{i_2} \dots w_{i_s} f(x_{i_1}, x_{i_2}, \dots, x_{i_s})$$

- Rychlost konvergence pro s -dimenzionální integrál je $O(N^{-1/s})$
 - Např. pro dvojnásobné zpřesnění odhadu 3-rozměrného integrálu musíme zvýšit počet vzorků $2^3 = 8$ krát
- Nepoužitelné pro vysokodimenzionální integrály
 - **Dimenzionální exploze**

Kvadraturní vzorce pro více dimenzí

- **Kvadraturní vzorce**

- V 1D lepší přesnost než Monte Carlo
- Ve 2D srovnatelné s MC
- Od 3D bude MC téměř vždy lepší

- **Kvadraturní metody NEJSOU metody Monte Carlo!**

Monte Carlo integrování

- Vzorky jsou rozmístěny náhodně (nebo pseudonáhodně)
- Konvergence: $O(N^{-1/2})$
 - **Konvergence nezávisí na dimenzionalitě**
 - Rychlejší než klasické kvadrurní vzorce pro 3 a více dimenzí
- Speciální metody pro rozmístění vzorků
 - Quasi-Monte Carlo, Randomized quasi-Monte Carlo
 - Ještě rychlejší konvergence než MC

Monte Carlo integrování – shrnutí

■ **Výhody**

- ❑ Jednoduchá implementace
- ❑ Robustní řešení pro různé tvary domén a integrandů
- ❑ Efektivní pro vícerozměrné integrály

■ **Nevýhody**

- ❑ Relativně pomalá konvergence – zmenšení statistické chyby o polovinu vyžaduje zvětšit počet vzorků čtyřikrát
- ❑ Pro syntézu obrazu: obrázek obsahuje šum

Náhodné veličiny

Náhodná veličina

- X ... náhodná hodnota
- X nabývá různých hodnot s různou pravděpodobností
 - $X \sim p(x)$
 - Rozložení pravděpodobnosti

Diskrétní náhodná veličina


- Konečná množina hodnot x_i
- S pravděpodobností p_i

$$p_i \equiv \Pr(X = x_i) \geq 0 \quad \sum_{i=1}^n p_i = 1$$


- **Distribuční funkce**
(cumulative distribution function)

$$P_i \equiv \Pr(X \leq x_i) = \sum_{j=1}^i p_j \quad P_n = 1$$

Pravděpodobnostní funkce (probability mass function)



Distribuční funkce



Spojité náhodná veličina

- **Hustota pravděpodobnosti $p(x)$**
(probability density function, **pdf**)

$$\Pr(X \in D) = \int_D p(x) dx$$

- V 1d:

$$\Pr(a < X \leq b) = \int_a^b p(t) dt$$

Spojité náhodná veličina

- **Distribuční funkce $P(x)$**
(cumulative distribution function, **cdf**)
V 1d:

$$P(x) \equiv \Pr(X \leq x) = \int_{-\infty}^x p(t) dt$$

$$\Pr(X = a) = \int_a^a p(t) dt = 0!$$


Spojité náhodná veličina

Rovnoměrné rozdělení (uniform distribution)

Hustota
pravděpodobnosti
(**pdf**)




Distribuční
funkce (**cdf**)




Spojité náhodná veličina

Gaussové (normální) rozdělení

Hustota
pravděpodobnosti
(pdf)



Distribuční
funkce (cdf)



Zdroj: wikipedia

Stř. hodnota a rozptyl

- **Stř. Hodnota** (očekávaná hodnota, expected value)

$$E[X] = \int_D \mathbf{x} p(\mathbf{x}) d\mathbf{x}$$

- **Rozptyl** (variance)

$$\begin{aligned} V[X] &= E[(X - E[X])^2] \\ &= E[X^2 - 2XE[X] + E[X]^2] \\ &= E[X^2] - E[X]^2 \end{aligned}$$

- **Vlastnosti**

$$V\left[\sum_i X_i\right] = \sum_i V[X_i] \quad (\text{pokud jsou } X_i \text{ nezávislé})$$

$$V[aX] = a^2 V[X]$$

Transformace náhodné veličiny

$$Y = f(X)$$

- Y je náhodná veličina
- Stř. hodnota Y

$$E[Y] = \int_D f(\mathbf{x}) p(\mathbf{x}) d\mathbf{x}$$

Monte Carlo integrování

Primární estimátor urč. integrálu


Odhadovaný integrál:

$$I = \int_{\Omega} f(x) dx$$

Je-li X náhodná veličina s distribucí $p(x)$, pak $Y = f(X)/p(X)$ je tzv. **primární estimátor** integrálu:

$$F_{\text{prim}} = Y = \frac{f(X)}{p(X)}$$

Primární estimátor urč. integrálu




Estimátor

- **Estimátor je náhodná veličina**
 - Vznikla transformací jiné náhodné veličiny
- Její **realizace** (hodnota) je konkrétní **odhad** (**estimate**)

Nestrannost obecného estimátoru

■ Nestrannost estimátoru (obecně):

- V průměru estimátor dává správnou veličinu (bez systematické chyby)



Nestrannost

Náš estimátor F_{prim} je nestranným (**unbiased**) odhadem I

$$\begin{aligned} E[F_{\text{prim}}] &= E[Y] \\ &= \int_{\Omega} \frac{f(x)}{p(x)} p(x) dx \\ &= I \end{aligned}$$

Rozptyl estimátoru F_{prim}

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

$$\underline{V[F_{\text{prim}}] = \sigma_{\text{prim}}^2 = E[Y^2] - E[Y]^2 = \int_{\Omega} \frac{f(x)^2}{p(x)} dx - I^2}$$

(pro nestranný odhad)

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

Sekundární estimátor integrálu

- N nezávislých náhodných veličin, $Y_i = f(X_i) / p(X_i)$

$$\begin{aligned} F_N &= \frac{1}{N} \sum_{i=1}^N Y_i \\ &= \frac{1}{N} \sum_{i=1}^N \frac{f(X_i)}{p(X_i)} \end{aligned}$$

- Sekundární estimátor je **nestranný**

Rozptyl sekundárního estimátoru


$$\begin{aligned}V[F_N] &= V\left[\frac{1}{N} \sum_{i=1}^N Y_i\right] \\&= \frac{1}{N^2} \cdot N \cdot V[Y_i] \\&= \frac{1}{N} V[Y_i] \\&= \frac{1}{N} V[F_{\text{prim}}]\end{aligned}$$

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

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
 - Tj. **pdf** p je „podobná“ integrandu
- **Menší rozptyl** při zachování nestrannosti


Vzorkování podle důležitosti



Příklady MC estimátorů

Odhad irradiance – uniformní vzork.

$$E(\mathbf{x}) = \int_{H(\mathbf{x})} L_i(\mathbf{x}, \omega_i) \cdot \cos \theta_i \, d\omega_i$$



- Uniformní vzorkování:


$$p(\omega) = \frac{1}{2\pi}$$

- Estimátor:

$$\begin{aligned} F_N &= \frac{1}{N} \sum_{k=1}^N \frac{f(\omega_{i,k})}{p(\omega_{i,k})} \\ &= \frac{2\pi}{N} \sum_{k=1}^N L_i(\mathbf{x}, \omega_{i,k}) \cdot \cos \theta_{i,k} \end{aligned}$$

Odhad irradiance – cos vzork.

$$E(\mathbf{x}) = \int_{H(\mathbf{x})} L_i(\mathbf{x}, \omega_i) \cdot \cos \theta_i \, d\omega_i$$




- Importance sampling:

$$p(\omega) = \frac{\cos \theta}{\pi}$$

- Estimátor:


$$\begin{aligned} F_N &= \frac{1}{N} \sum_{k=1}^N \frac{f(\omega_{i,k})}{p(\omega_{i,k})} \\ &= \frac{\pi}{N} \sum_{k=1}^N L_i(\mathbf{x}, \omega_{i,k}) \end{aligned}$$

Computing Irradiance



4 eye rays per pixel
100 shadow rays

Odhad irradiance – vzrokování zdroje



Odhad irradiance – vzorkování zdroje

$$E(\mathbf{x}) = \int_{H(\mathbf{x})} L_i(\mathbf{x}, \omega_i) \cdot \cos \theta_i \, d\omega_i$$
$$= \int_A L_e(\mathbf{y} \rightarrow \mathbf{x}) \cdot V(\mathbf{y} \leftrightarrow \mathbf{x}) \cdot \frac{\cos \theta_y \cdot \cos \theta_x}{\|\mathbf{y} - \mathbf{x}\|^2} \, dA$$

$G(\mathbf{y} \leftrightarrow \mathbf{x})$
↙



- Uniformní vzorkování plochy zdroje:

$$p(\mathbf{y}) = \frac{1}{|A|}$$

- **Estimátor**

$$F_N = \frac{|A|}{N} \sum_{k=1}^N L_e(\mathbf{y}_k \rightarrow \mathbf{x}) \cdot V(\mathbf{y}_k \leftrightarrow \mathbf{x}) \cdot G(\mathbf{y}_k \leftrightarrow \mathbf{x})$$

Example – Area Sampling





1 shadow ray per eye ray

Center

Random

Example – Area Sampling




16 shadow rays per eye ray

Uniform grid

Stratified random

Plošné zdroje světla



1 vzorek na pixel

9 vzorků na pixel

36 vzorků na pixel

Přímé osvětlení na ploše s obecnou BRDF

- Odhadovaný integrál

$$L_o(\mathbf{x}, \omega_o) = \int_A L_e(\mathbf{y} \rightarrow \mathbf{x}) \cdot f_r(\mathbf{y} \rightarrow \mathbf{x} \rightarrow \omega_o) \cdot V(\mathbf{y} \leftrightarrow \mathbf{x}) \cdot G(\mathbf{y} \leftrightarrow \mathbf{x}) dA$$

- **Estimátor** (uniformní vzorkování povrchu zdroje)

$$F_N = \frac{|A|}{N} \sum_{k=1}^N L_e(\mathbf{y}_k \rightarrow \mathbf{x}) \cdot f_r(\mathbf{y}_k \rightarrow \mathbf{x} \rightarrow \omega_o) \cdot V(\mathbf{y}_k \leftrightarrow \mathbf{x}) \cdot G(\mathbf{y}_k \leftrightarrow \mathbf{x})$$

Nepřímé osvětlení na ploše s obecnou BRDF

- Odhadovaný integrál

Pozn. $L_o = L_r + L_e$

$$L_o^{\text{ind}}(\mathbf{x}, \omega_o) = \int_{H(\mathbf{x})} L_r(\mathbf{r}(\mathbf{x}, \omega_i), -\omega_i) \cdot f_r(\mathbf{x}, \omega_i \rightarrow \omega_o) \cdot \cos \theta_i \, d\omega_i$$

- **Estimátor** pro vzorkování směrů s obecnou pdf $p(\omega)$

$$L_o^{\text{ind}}(\mathbf{x}, \omega_o) = \frac{1}{N} \sum_{k=1}^N \frac{L_r(\mathbf{r}(\mathbf{x}, \omega_{i,k}), -\omega_{i,k}) \cdot f_r(\mathbf{x}, \omega_{i,k} \rightarrow \omega_o) \cdot \cos \theta_{i,k}}{p(\omega_{i,k})}$$

PDF úměrná nebo velmi podobná BRDF

Distribution Ray Tracing

Path tracing

Sledování cest od kamery

```
renderImage()  
{  
  for all pixels  
  {  
    Color pixelCol = (0,0,0);  
    for k = 1 to N  
    {  
      wk := náhodný směr skrz k-tý pixel  
      pixelCol += getLi(camPos,wk)  
    }  
    return Lo / N  
  }  
}
```

Distribution Ray Tracing

```
getLi(x, wi)
{
    hit := NearestIntersect(x, wi)
    wo := -wi;
    y := hit.pos;
    if no intersection
        return backgroundCol;
    else
    {
        Lo = (0,0,0)
        for k = 1 to N
        {
            wk := náhodný směr na hemisféře s hustotou p(w)
            Lo += getLi(y, wk) * fr(y, wk, wo) * dot(hit.n,wk) / p(wk)
        }
        return Lo / N + directLighting (y, wo);
    }
}
```

Distribution Ray Tracing

- Ad hoc ukončení rekurze
 - maximální povolená hloubka
 - minimální povolený příspěvek

Sledování cest (Path tracing)

- Pouze jeden sekundární paprsek
 1. vyber způsob interakce (ideální lom, difúzní odraz, ...)
 2. použij importance sampling podle vybrané interakce
- Přímé osvětlení
 - Doufej, že náhodně vygenerovaný paprsek trefí zdroj, anebo
 - Vyber náhodně jeden vzorek na jednom zdroji světla
- Trasuj stovky cest přes každý pixel a zprůměruj výsledek
- Výhoda: žádná exploze počtu paprsků kvůli rekurzi

Path Tracing – Implicitní osvětlení

```
getLi(x, w)
{
    Color thrput = (1,1,1)
    Color accum = (0,0,0)
    while(1)
    {
        hit = NearestIntersect(x, w)
        if no intersection
            return accum + thrput * bgRadiance(x, w)
        if isOnLightSource(hit)
            accum += thrput * Le(hit.pos, -w)
        ρ = reflectance(hit.pos, -w)
        if rand() < ρ // russian roulette - survive (reflect)
            wi := SampleDir(hit)
            thrput *= fr(hit.pos, wi, -w) * dot(hit.n, wi) / (ρ*p(wi))
            x := hit.pos
            w := wi
        else // absorb
            break;
    }
    return accum;
}
```

Ukončení rekurze – Ruská ruleta

- Pokračuj v rekurzi s pravděpodobností q
- Uprav váhu faktorem $1 / q$

$$Z = \begin{cases} Y / q & \text{pokud } \xi < q \\ 0 & \text{jinak} \end{cases}$$

$$E[Z] = \frac{E[Y]}{q} \cdot q + 0 \cdot \frac{1}{q-1} = E[Y]$$