

Moderní fotorealistický rendering

© 2010-2016 Josef Pelikán, CGG MFF UK
2016 Jiří Vorba a Jaroslav Křivánek, dtto

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

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

Seminář Ústavu teoretické fyziky, 6. 12. 2016



Obsah přednášky

- ◆ cíle a aplikace realistického zobrazování
- ◆ historie, přehled používaných přístupů
 - ◆ Ray-tracing, radiační metody
- ◆ teoretické základy – zobrazovací rovnice
 - ◆ souhlas starších metod s teorií (fyzikou)
- ◆ metody založené na zobrazovací teorii
 - ◆ Monte-Carlo zobrazování (paprsky, „unbiased“)
 - ◆ hybridní metody (efektivita)
 - ◆ Photon-mapping
 - ◆ Metropolis sampling
 - ◆ ADRRS (Vorba, Křivánek, SIGGRAPH 2016)

Fotorealistické zobrazování



Fotorealistické zobrazování



Cíle realistického zobrazování



- ♦ věrně **napodobit přírodu**
 - ♦ virtuální scéna reprezentovaná v počítači
- ♦ přesně **simulovat šíření světla** ve scéně
 - ♦ „predictive rendering“
- ♦ nebo „**důvěryhodné zobrazování**“
 - ♦ laický pozorovatel nemá poznat, že je obrázek umělý ...
- ♦ **rychlost** vykreslování
 - ♦ „off-line“ rendering (nezáleží tolik na rychlosti)
 - ♦ „real-time“ (min. 25 fps)

Aplikace

- ◆ design, architektura, umění
 - ◆ šíření světla v interiéru, kabině, ..
- ◆ zábavní průmysl
 - ◆ filmy (IL&M, Pixar, DreamWorks, ... „off-line“)
 - ◆ videohry („real-time“)
- ◆ média
 - ◆ televize (virtuální studia, ...)
 - ◆ reklamy






Historie

- ◆ cíle a aplikace realistického zobrazování
- ◆ **historie, přehled používaných přístupů**
 - ◆ Ray-tracing, radiační metody
- ◆ teoretické základy – zobrazovací rovnice
 - ◆ souhlas starších metod s teorií (fyzikou)
- ◆ metody založené na zobrazovací teorii
 - ◆ Monte-Carlo zobrazování (paprsky, „unbiased“)
 - ◆ hybridní metody (efektivita)
 - ◆ Photon-mapping
 - ◆ Metropolis sampling
 - ◆ ADRRS (Vorba, Křivánek, SIGGRAPH 2016)


Historie – klasické zobrazování



- ◆ Straßer, Catmull 1974: Z-buffer
- ◆ **ploškový model**
 - ◆ nejčastěji trojúhelníkové sítě
- ◆ **výpočet viditelnosti**
 - ◆ Z-buffer
- ◆ **přibližné světelné poměry**
 - ◆ lokální osvětlovací model, vržené stíny
- ◆ **textury, shadery**



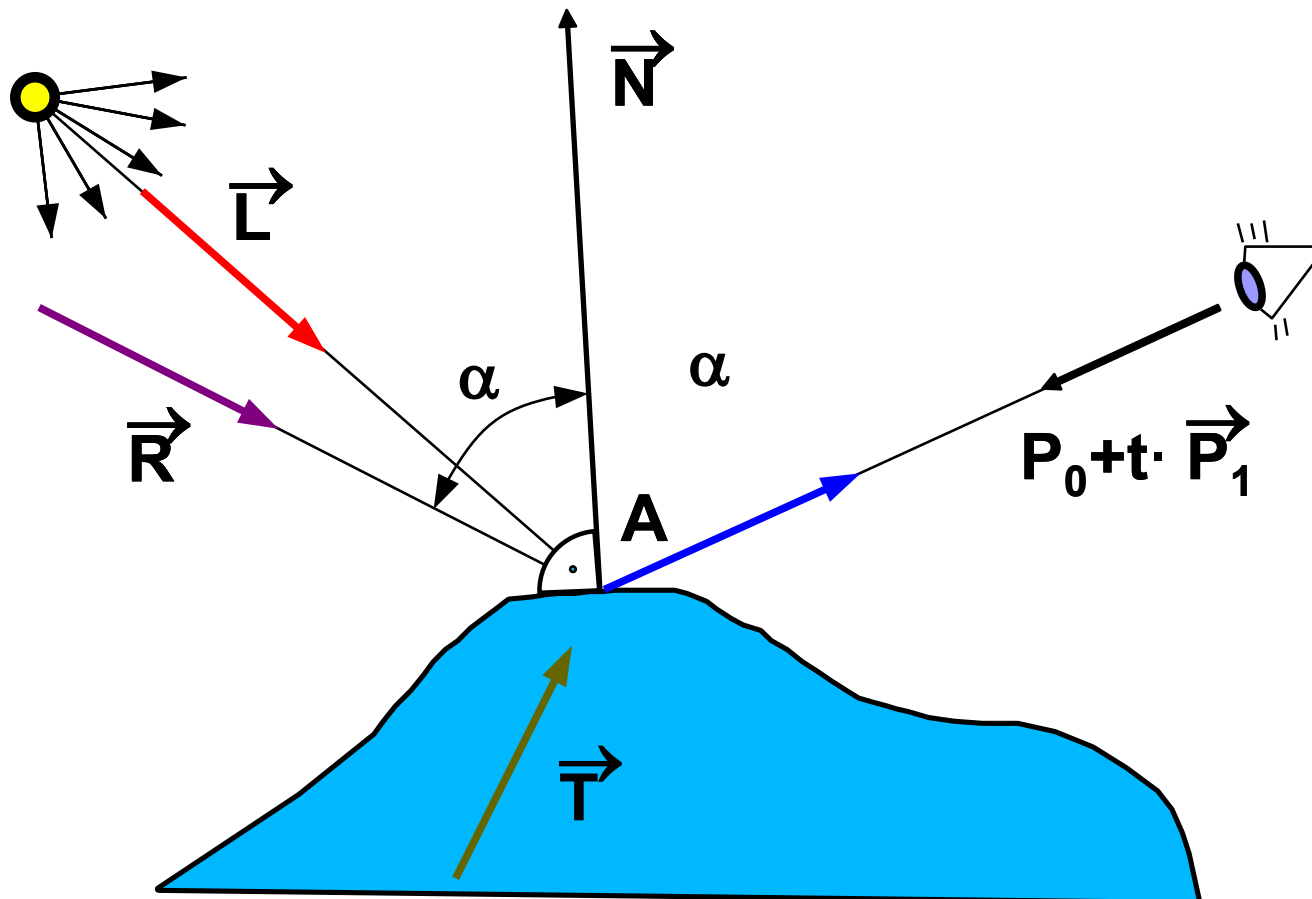
Historie – Ray-tracing I




- ◆ Whitted 1980: základní Ray-tracing
- ◆ **geometrický přístup**
 - ◆ sleduje se jenom ideálně odražený paprsek
- ◆ výpočetně velmi náročný **výpočet průsečíku** paprsku se scénou
 - ◆ 95% času → urychlovací metody
- ◆ snadné **vylepšení vzhledu**
 - ◆ textury, anti-aliasing, shadery
 - ◆ distribuované techniky (viz dále)



Historie – Ray-tracing II



Ray-tracing – příklady



Ray-tracing – příklady



Ray-tracing – příklady




Ray-tracing – příklady



Historie – Distributed RT


- ◆ Cook 1984: Distributed Ray Tracing
- ◆ **vylepšení kvality výsledku**
 - ◆ integrál nahrazuje původně jediný vzorek
 - ◆ měkké stíny, odrazy, lomy, difrakce
 - ◆ rozmazání pohybem
 - ◆ hloubka ostrosti kamery
- ◆ výpočetně velmi náročné metody
 - ◆ Monte-Carlo algoritmy
 - ◆ stonásobně víc paprsků...



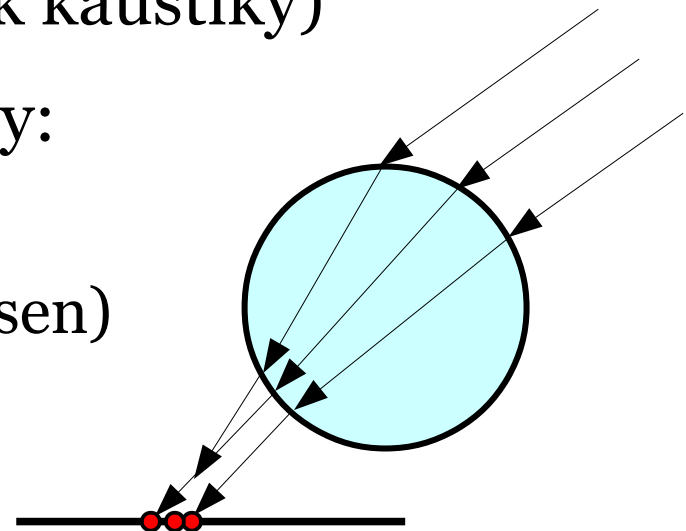
Distributed RT – příklad



Historie – Bidirectional RT




- ◆ Arvo 1986: Backward Ray Tracing
- ◆ sledování **opačného směru**
 - ◆ v první fázi se paprsky posílají ze světla a zachytávají na plochách
 - ◆ vykreslení „kaustiky“ (1986 = rok kaustiky)
 - ◆ později se z toho vyvinuly metody:
 - Light-tracing, Photon-tracing
 - Photon-maps (Henrik Wann Jensen)



Historie – Radiační metoda I

- ◆ Goral et al. 1984: Illumination for Computer-Generated Pictures
- ◆ předpoklad **difusních** materiálů
 - ◆ Lambertův zákon (dokonalý rozptyl světla)
 - ◆ metoda konečných prvků vede na **soustavu lineárních rovnic**
- ◆ různá **vylepšení**:
 - ◆ iterace à la Southwell
 - ◆ hierarchické přístupy
 - ◆ zobecněné konfigur. faktory (lesk)





Historie – Radiační metoda II

- ♦ základní rovnice pro **radiositu** i-té plošky:

$$B_i = E_i + \rho_i \cdot \sum_{j=1}^N B_j \cdot \frac{1}{A_i} \int_{A_i} \int_{A_j} g(y, x) dA_j dA_i$$


geometrický člen - **konfigurační faktor** F_{ij}
(část výkonu vyzářeného ploškou A_i dopadající na A_j)

$$B_i = E_i + \rho_i \cdot \sum_{j=1}^N B_j F_{ij} \quad \left[\frac{W}{m^2} \right]$$

Radiační metoda – příklady



Radiační metoda – příklady




Radiační metoda – příklady



Historie – Hybridní metody




- ◆ Wallace 1987, Sillion 1989, 1991, ...
- ◆ radiální metoda umí dobře **difusní** materiály
- ◆ metody založené na paprscích umí dobře **lesklý** odraz
 - ◆ Ray-tracing, Distributed R-T
 - ◆ Path-tracing, Photon-tracing, ...
- ◆ **kombinace** několika metod
 - ◆ pozor na duplikace!
 - ◆ většinou sériové zapojení = více fází za sebou
 - ◆ vykreslení: Ray-tracing, Path-tracing



Historie – Zobrazovací rovnice



- ◆ J. T. Kajiya: The Rendering Equation (SIGGRAPH '86)
- ◆ matematický přístup k zobrazování
 - ◆ integrální rovnice popisující šíření světla, nestranné řeš.
- ◆ algoritmy založené na **Monte-Carlo**
 - ◆ .. přesné (analytické) řešení není možné
- ◆ **Path-tracing** (už Kajiya)
 - ◆ později: Light-tracing, Photon-tracing, Bidirectional Path-tracing, hybridní alg., Metropolis metody






Teoretické základy

- ◆ cíle a aplikace realistického zobrazování
- ◆ historie, přehled používaných přístupů
 - ◆ Ray-tracing, radiační metody
- ◆ **teoretické základy – zobrazovací rovnice**
 - ◆ souhlas starších metod s teorií (fyzikou)
- ◆ metody založené na zobrazovací teorii
 - ◆ Monte-Carlo zobrazování (paprsky, „unbiased“)
 - ◆ hybridní metody (efektivita)
 - ◆ Photon-mapping
 - ◆ Metropolis sampling
 - ◆ ADRRS (Vorba, Křivánek, SIGGRAPH 2016)

BRDF (lokální funkce odrazivosti)




(„Bidirectional Reflectance Distribution Function“)




$$f_r(\omega_i, \omega_o) = \frac{\partial L_r(\omega_o)}{\partial E(\omega_i)} = \frac{\partial L_r(\omega_o)}{L_i(\omega_i) \cos \theta_i \partial \omega_i}$$

Klasické složky odrazu světla



Difusní („diffuse“)




Lesklý („specular“)

$$f_r(\omega_i, \omega_o) = f_{r,d}(\omega_i, \omega_o) + f_{r,s}(\omega_i, \omega_o)$$

Lokální zobrazovací rovnice



„OVTIGRE“



vakuum:
 $L_i(x, \omega_i) = L_o(y, -\omega_i)$


vyzařování zdroje

$$\underline{L_o(x, \omega_o)} = \underline{L_e(x, \omega_o)} + \int f_r(x, \omega_i \rightarrow \omega_o) \cdot \underline{L_o(y, -\omega_i)} \cdot \cos \theta_{xi} d\omega_i$$




Lokální světelné modely

- ◆ **Bouknight** 1970: difusní (Lambert) a ambient
- ◆ **Gouraud** 1971: interpolace barvy z vrcholů
- ◆ **Phong** 1975: navíc lesklá složka, interpolace normály
- ◆ **Blinn** 1977, **Cook** et al. 1982: „mikroplošky“
- ◆ **Kajiya** 1985, **Cabral** et al. 1987: vylepšení (anizotrop.)
- ◆ **Wolf** 1990: polarizace odraženého světla
- ◆ **Oren-Nayar** 1993: difusní mikroplošky
- ...




Příklady BRDF



(a)

(b)

(c)



(d)

(e)

(f)



(g)

(h)

(i)


Příklady BRDF




Příklady BRDF – latexový nátěr




- ◆ stříkaný latexový (matnější) lak




Příklady BRDF – latexový nátěr




0° (kolmo)




35°



55°



75°



75° (zmenšeno)

Doplnění – radiometrické veličiny



- **výkon** procházející nějakou plochou („radiant flux“):
 $\Phi_i (\Phi_o)$ [W]

$$\Phi = \frac{\partial Q}{\partial t}$$


- **radiosita (irradiance)** – hustota výkonu na ploše:
 $B_o (E, B_i)$ [W / m²]

$$E(p) = \frac{\partial \Phi(p)}{\partial A}$$

Radiance – cíl „renderingu“



- přijímaná (výsledná, vlastní) **radiance** v bodě **p** a směru ω : $L_i(\mathbf{p}, \omega)$ ($L_o(\mathbf{p}, \omega)$, $L_e(\mathbf{p}, \omega)$) [W / m² sr]



$$\begin{aligned} L_o(p, \omega) &= \frac{\partial^2 \Phi(p, \omega)}{\partial A \partial \omega \cos \theta} \\ &= \frac{\partial E(p, \omega)}{\partial \omega \cos \theta} \end{aligned}$$

Je **konstantní na paprsku** ve vakuu.
Vyjadřuje **jas** vnímaný okem/kamerou.

Irradiance



- příchozí hustota výkonu – integrace přes celou horní hemisféru:

$$E(p) = \int_{\Omega^+} L_i(p, \omega) \cos \theta \, d\omega$$

Souhlas starších metod s teorií



- ◆ cíle a aplikace realistického zobrazování
- ◆ historie, přehled používaných přístupů
 - ◆ Ray-tracing, radiační metody
- ◆ teoretické základy – zobrazovací rovnice
 - ◆ **souhlas starších metod s teorií (fyzikou)**
- ◆ metody založené na zobrazovací teorii
 - ◆ Monte-Carlo zobrazování (paprsky, „unbiased“)
 - ◆ hybridní metody (efektivita)
 - ◆ Photon-mapping
 - ◆ Metropolis sampling
 - ◆ ADRRS (Vorba, Křivánek, SIGGRAPH 2016)

Operátory šíření světla



Zobrazovací rovnice pro **radianci**:

$$L = e + TL$$

$$L = e + Te + T^2e + T^3e + \dots \quad (\text{Neumannova řada})$$

Integrální **operátor T** lze rozložit na difusní (**D**) a lesklou (**S**) složku odrazu:

$$T = D + S$$

$$L = e + (D + S)e + (D + S)^2e + \dots$$

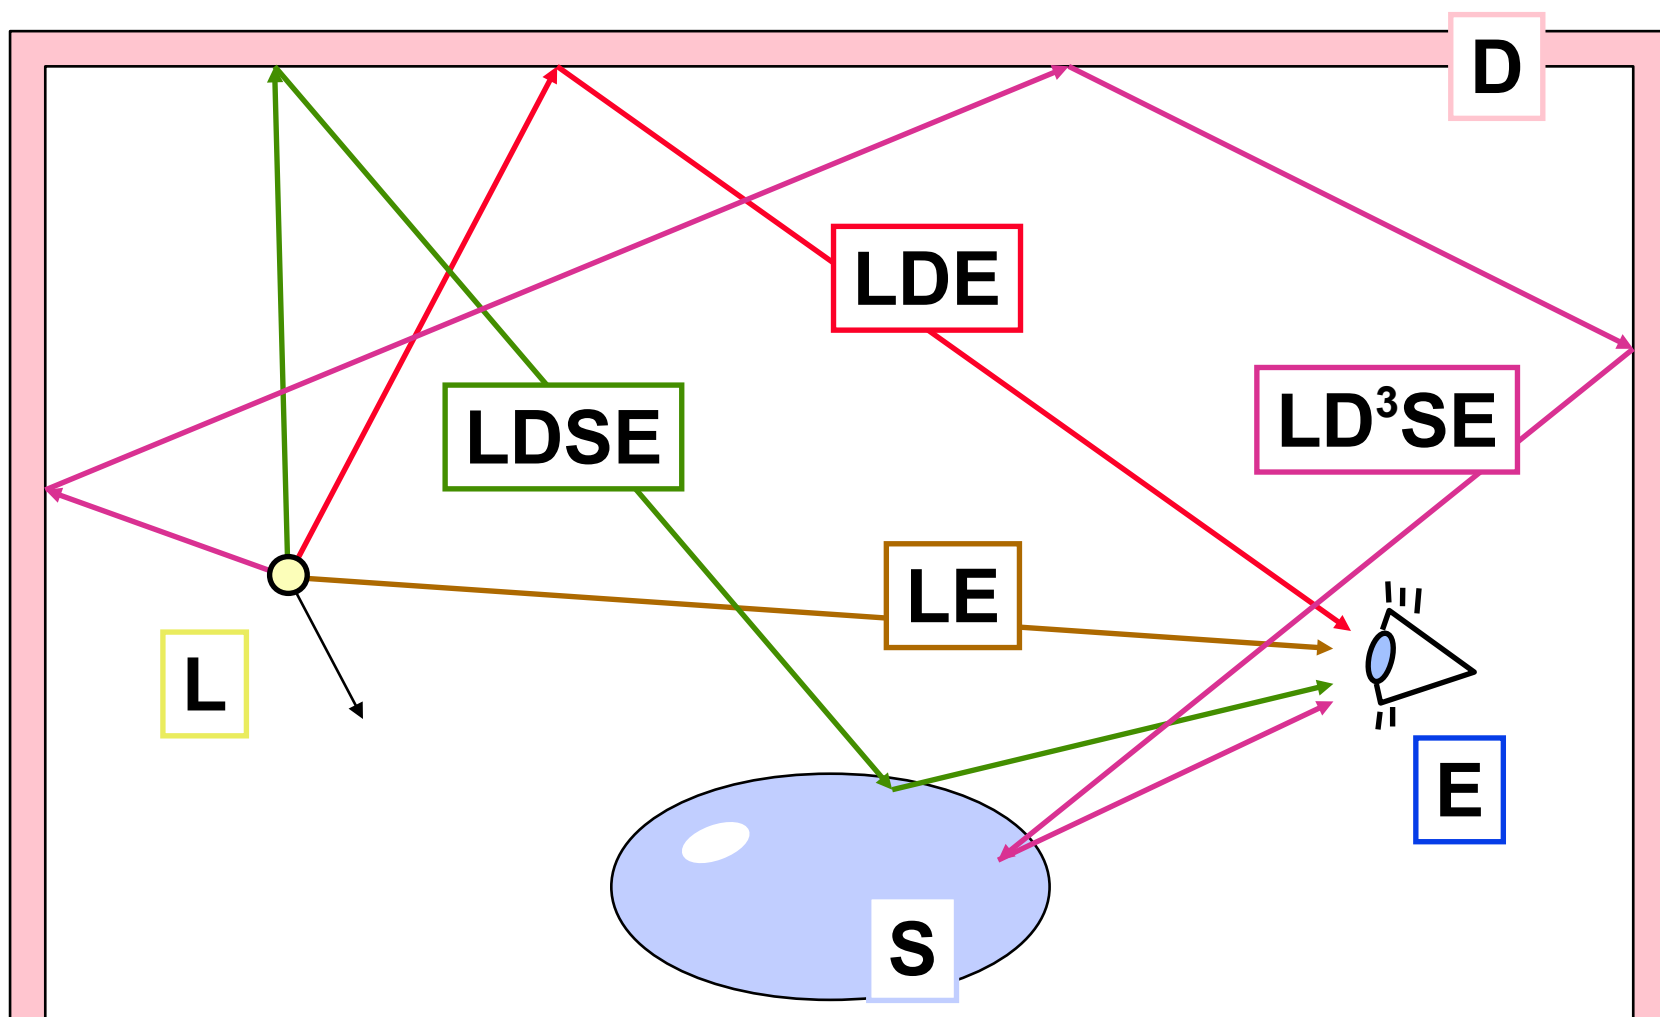
$$L = e + De + Se + DDe + DSe + SDe + SSe + \dots$$



Abeceda regulárních výrazů

- ◆ **zdroj světla L** („light“)
- ◆ **difusní odraz D** („diffuse“)
 - ◆ odraz podle Lambertova zákona (všesměrový)
- ◆ **lesklý odraz S** („specular“)
 - ◆ směrový odraz, odlesk – směrová část BRDF
 - ◆ idealizovaný **zrcadlový odraz: S_M**
- ◆ **oko pozorovatele E** („eye“)
 - ◆ příspěvek výslednému obrazu

Cesty šíření světla



Přehled zobrazovacích metod



- ◆ **stínování s odlesky a vrženými stíny** (např. Phongův model): $L (D | S) E$
 - často se ignoruje výpočet vržených stínů
- ◆ **Ray-tracing (Whitted):** $L [D | S] S_M^* E$
 - první lesklý odraz se počítá přesně, ostatní se nahrazují ideálním zrcadlovým odrazem
- ◆ **Distributed Ray-tracing (Cook):** $L [D] S^* E$
 - všechny lesklé odrazy se odhadují korektně

Přehled zobrazovacích metod



- ◆ obyčejná **radiační metoda**: $L D^* E$
 - pouze difusní odraz světla
- ◆ **všechny možné cesty světla**: $L (D | S)^* E$
 - přesné řešení zobrazovacích rovnic, nestranné Monte-Carlo metody
 - první z nich byla „Path-tracing“ (Kajiya)



Monte-Carlo zobrazování

- ◆ cíle a aplikace realistického zobrazování
- ◆ historie, přehled používaných přístupů
 - ◆ Ray-tracing, radiační metody
- ◆ teoretické základy – zobrazovací rovnice
 - ◆ souhlas starších metod s teorií (fyzikou)
- ◆ **metody založené na zobrazovací teorii**
 - ◆ **Monte-Carlo zobrazování (paprsky, „unbiased“)**
 - ◆ hybridní metody (efektivita)
 - ◆ Photon-mapping
 - ◆ Metropolis sampling
 - ◆ ADRRS (Vorba, Křivánek, SIGGRAPH 2016)

Monte-Carlo zobrazování



- ◆ **Monte-Carlo kvadratura:** integrály zobrazovacích rovnic jsou **mnoho-rozměrné**
 - ◆ anti-aliasing, hloubka ostrosti, rozmazání pohybem
 - ◆ Monte-Carlo metody nejsou citlivé na vyšší dimenze
- ◆ integrandy mají mnoho **nespojností** různých druhů
- ◆ obyčejně se nepožaduje velká přesnost
 - ◆ lidské vidění má velmi omezenou absolutní citlivost
 - ◆ běžně postačí relativní přesnost $1/2 \div 4 \%$

Urychlení konvergence M–C




- ◆ „jittering“, „stratified sampling“
 - ◆ vzorkování s nižší diskrepancí
- ◆ vzorkování podle důležitosti („importance sampling“)
 - ◆ hustota pravděpodobnosti podobná integrované funkci
 - ◆ generování vzorků s libovolnou hustotou pravděpodob.
- ◆ kombinované odhady, smíšené heuristiky (různé pr.)
 - ◆ různá vzorkování (= hustoty pravděpodobnosti) pro různé složky integrované funkce
- Metropolis vzorkování (super-nerovnoměrné distr.)


Příklady M-C zobrazování



Příklady M-C zobrazování



Stratified sampling




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

$$\langle I \rangle_{strat} = \sum_{i=1}^N f(\xi_i) \mu(A_i)$$

$$\xi_i \in A_i$$

- „chytrý“ rozklad na subintervaly:
- funkce $f(x)$ má na subintervalech co nejmenší variaci

Importance sampling



$$\int_0^1 f(x) d\mu(x) = \int_0^1 \frac{f(x)}{p(x)} dp(x)$$


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

$$\xi_i \in Rnd(p)$$

- hustota $p(x)$ má být co nejpodobnější funkci $f(x)$
- ?! efektivní generování vzorků podle hustoty $p(x)$!?



Combined sampling (MIS)



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

$$\xi_i \in Rnd(p_i)$$

$$0 \leq w_i(x)$$

$$\sum_{i=1}^N w_i(x) = 1$$

- odhaduje se podle několika náhodných rozdělení
- každé rozdělení může charakterizovat jinou složku $f(x)$..



Příklady heuristik

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

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

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

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



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



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

Mocninná heuristika

$$\beta = 2$$

Obě
vzorkování !





Náhodná procházka

- ◆ řešení Fredholmovy soustavy druhého druhu:

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

neznámá funkce zadání


- nekonečná náhodná procházka řízená distribucemi p_i

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



Ruská ruleta

- odstranění nekonečného výpočtu (řady)
- stochastický přístup: jen s jistou pravděpodobností $P < 1$ se pokračuje (počítá..)
- nutná kompenzace výsledku: P^{-1}




Ruská ruleta pro Neumannovy řady

- odstranění nekonečné procházky:

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

- P_j udává pravděpodobnost pokračování v kroku j
- je logické, aby byla úměrná celkové odrazivosti $\int K(x, y)$
- $p_j(x)$ je distribuce pro výběr dalšího prvku posloupnosti: ξ_j

Zobrazovací rovnice pro radianci



$$\begin{aligned} L(x, \omega_x) &= \\ &= L_e(x, \omega_x) + \int_{\Omega_x^{-1}} f(x, \omega_y \rightarrow \omega_x) \cdot L(y, \omega_y) \cdot \cos \theta_y \, d\omega_y \\ \Phi_o(S) &= \int_A \int_{\Omega_x} L(x, \omega_x) \cdot W_e(x, \omega_x, S) \cdot \cos \theta_x \, d\omega_x \, dA_x \end{aligned}$$



Path-tracing


Monte-Carlo odhad toku $\Phi(\mathbf{S})$ i radiance $\mathbf{L}(\mathbf{x}_0, \omega_0)$
(omezení náhodné procházky ruskou ruletou):

$$\langle \Phi(\mathcal{S}) \rangle_{path} = \frac{W_e(x_0, \omega_0, \mathcal{S}) \cdot \cos \psi}{p_0(x_0, \omega_0)} \cdot \sum_{i=0}^k \left[\prod_{j=1}^i \frac{f(x_{j-1}, \omega_j \rightarrow \omega_{j-1}) \cdot \cos \theta_{j-1}}{P_j \cdot p_j(\omega_j)} \right] \cdot L_e(x_i, \omega_i)$$

pravděpodobnost
pokračování krokem \mathbf{j}


hustota pravděp.
pro vstupní směr ω_j

PT – postup výpočtu (procházka)





PT – šíření světla





Odhad příští události (NEE)

- ◆ obyčejný Path-tracing je velmi **neefektivní**
 - náhodná procházka se musí trefit do zdroje světla!
- ◆ **odhad příští události** („Next Event Estimation“)
 - zařídím příspěvky od zdrojů v každém kroku
- ◆ NEE je nejvýhodnější pro scény s **malými** ale **dobře viditelnými** plochami světelných zdrojů
 - ◆ vzorkování světelných zdrojů tvoří dominantní složku výsledku



Odhad příští události II

Rozdělení **nepřímého osvětlení** na dvě složky:


$$L(x, \omega_x) = L_e(x, \omega_x) + L_r(x, \omega_x)$$

$$\underline{L_r(x, \omega_x)} = \int_{\Omega_x^{-1}} f(x, \omega_y \rightarrow \omega_x) \cdot L(y, \omega_y) \cdot \cos \theta_y \, d\omega_y =$$

$$= \int_A f(x, \omega_y \rightarrow \omega_x) \cdot L_e(y, \omega_y) \cdot G(y, x) \, dA_y +$$
$$+ \int_{\Omega_x^{-1}} f(x, \omega_y \rightarrow \omega_x) \cdot L_r(y, \omega_y) \cdot \cos \theta_y \, d\omega_y$$




Schema šíření světla (PT+NEE)



Light-tracing - příklad




Photon-tracing - příklad (kaustika)






LT - šíření světla (střílení)





NEE pro Light-tracing





Aplikace Light-tracingu

- ◆ **přímý výpočet realistického obrázku**
 - ◆ světlo se přijímá kamerou a ukládá v průmětně
- ◆ **pomocný výpočet** pro některou kombinovanou metodu
 - ◆ světlo se ukládá do tzv. světelných map (fotonové mapy, „Photon-tracing“)
 - ◆ větší suma potenciálu W_e vede k efektivnějšímu výpočtu (nemusí se dělat NEE)
 - ◆ **„Photon-mapping“**: moderní, ale ne zcela korektní metoda zobrazování (Henrik Wann Jensen, 1995)



Obousměrný Path-tracing

Uzavřené i neuzavřené cesty světla:

$$\langle \Phi(\mathbf{S}) \rangle_{\text{bipath,nee}} = \sum_{i=-1}^k \sum_{j=-1}^{k^*} w_{ij} C_{ij}$$

$i = -1, j > 0$: cesta od pozorovatele (bez NEE)

$i = 0, j \geq 0$: cesta od pozorovatele se vzorkem na zdroji


$i > 0, j > 0$: světlo i -krát odražené od zdroje a j -krát od pozorovatele

$i \geq 0, j = 0$: cesta od zdroje se vzorkem na receptoru

$i > 0, j = -1$: cesta od zdroje (bez NEE - neefektivní)



Obecná cesta (obousměrná)



Bidir PT – přehled vzorkování



závislost příspěvku na		vzorku na cestě od zdroje světla				
		x_0	x_1	x_2	x_3	
vzorku na cestě od receptoru		PT				
		LT		$C_{1,-1}$	$C_{2,-1}$	$C_{3,-1}$
	y_{-1}		$C_{0,0}$	$C_{1,0}$	$C_{2,0}$	$C_{3,0}$
	y_0	$C_{-1,1}$	$C_{0,1}$	$C_{1,1}$	$C_{2,1}$	$C_{3,1}$
y_2	$C_{-1,2}$	$C_{0,2}$	$C_{1,2}$	$C_{2,2}$	$C_{3,2}$	

Příklad rozkladu výpočtu



© 1995 Eric Veach,
Leonidas J. Guibas

Bidir PT – příklady



Bidir PT – příklady



Bidir PT – příklady





Hybridní metody

- ◆ cíle a aplikace realistického zobrazování
- ◆ historie, přehled používaných přístupů
 - ◆ Ray-tracing, radiační metody
- ◆ teoretické základy – zobrazovací rovnice
 - ◆ souhlas starších metod s teorií (fyzikou)
- ◆ metody založené na zobrazovací teorii
 - ◆ Monte-Carlo zobrazování (paprsky, „unbiased“)
 - ◆ **hybridní metody (efektivita)**
 - ◆ Photon-mapping
 - ◆ Metropolis sampling
 - ◆ ADRRS (Vorba, Křivánek, SIGGRAPH 2016)


Vícekové (hybridní) metody



- ◆ kombinace **radiačních metod** (difusní odrazy) a **sledování paprsku** (lesklé odrazy)
 - ◆ většinou se tyto dva přístupy střídají (algoritmus se dělí na jednotlivé „průchody“ nebo kroky)
- ◆ **radiační přístup** řeší (nepřímé) difusní osvětlení: D^*
- ◆ **sledování paprsku** počítá lesklé odrazy: $S_{[M]}^*$
 - ◆ navíc se používá pro finální průchod (zobrazení)
 - ◆ místo R-T lze použít **Path-tracing** nebo jeho vylepšení



Mezivýsledek = světelná mapa





Optimální hybridní metody

- ◆ rozklad celkové množiny cest světla $L (D | S)^* E$ na disjunktní podmnožiny
 - ◆ každou řešíme algoritmem, který tam nejlépe konverguje
 - ◆ např. difusní šíření světla radiálními metodami nebo pomocí „Irradiance caching“
- ◆ příklad – **Chen et al. (1991)**:
 - ◆ $L [D] S^* E$ – M-C Path-tracing
 - ◆ $L S^+ D S^* E$ – **Photon-tracing** na difusních plochách + **M-C Path-tracing** do první difusní plochy
 - ◆ $L (D|S)^* D S^* D S^* E$ – **progresivní radiální metoda** (zobecněné form-factory) + **M-C Path-tracing** do 2. dif.pl.



Photon-Mapping

- ◆ cíle a aplikace realistického zobrazování
- ◆ historie, přehled používaných přístupů
 - ◆ Ray-tracing, radiační metody
- ◆ teoretické základy – zobrazovací rovnice
 - ◆ souhlas starších metod s teorií (fyzikou)
- ◆ metody založené na zobrazovací teorii
 - ◆ Monte-Carlo zobrazování (paprsky, „unbiased“)
 - ◆ hybridní metody (efektivita)
 - ◆ **Photon-mapping**
 - ◆ Metropolis sampling
 - ◆ ADRRS (Vorba, Křivánek, SIGGRAPH 2016)



Základy Photon-mappingu

- ◆ založen na **vrhání paprsků**
 - libovolná **geometrie scény**
 - využití dlouho laděných **knihoven, urychlovacích technik**, apod.
- světlo se sleduje **zepředu** (od zdroje) i **zezadu** (od kamery)
 - ◆ kamera reprezentuje důležitost (potenciál)
 - ◆ světla jsou zdroje fotonů
- ◆ oddělení geometrie scény od reprezentace světla
 - ◆ umožňuje mít libovolně složitou 3D scénu
 - ◆ reprezentaci světla lze nezávisle optimalizovat



Fotonová mapa (Photon-map)

- ◆ datová struktura ukládající **dopady jednotlivých fotonů**
 - reprezentuje dobře i velmi variabilní funkci osvětlení
 - zcela oddělena od geometrie scény
 - úsporná reprezentace v paměti
- „cache cest světla obousměrného Path-tracingu“
 - ◆ odhad funkce osvětlení však nevykazuje VF šum
 - ◆ .. při stejné kvalitě je mnohem rychlejší než M-C techniky
- ◆ ztráta **nestrannosti** !
 - ◆ ale konzistentní (konverguje při zvětšování počtu fotonů)




Struktura algoritmu

◆ Photon-tracing


- ◆ fotony jsou generovány světelnými zdroji,
- ◆ propagují se do scény (Monte-Carlo)
- ◆ a ukládají se do fotonových map (**globální** pro pomalé změny a **kaustická** pro koncentraci světla)

◆ zobrazení (Rendering)

- ◆ informace uložené ve fotonové mapě se používají k efektivnímu zobrazení scény
- ◆ obyčejný Ray-tracing nebo
- ◆ Monte-Carlo metoda (Path-tracing)



Photon-mapping - příklady



Photon-mapping - příklady




Photon-mapping - příklady





Photon-tracing

- ▶ **generování fotonů** světelnými zdroji,
- ▶ jejich **náhodný průchod scénou** a
- ▶ **ukládání do fotonové mapy**







Generování fotonů

- ◆ nejvýhodnější přístup – každý foton nese **stejnou světelnou energii**
- ◆ **náhodné vzorkování** vyzařovacích funkcí světelných zdrojů
 - ◆ „rejection sampling“ pro obtížné distribuce
- ◆ **více světelných zdrojů..**
 - ◆ distribuce mezi nimi na základě jejich celkového výkonu
- ◆ **efektivní vzorkování**
 - ◆ předem připravené **projekční mapy** (viz akcelerace Ray-tracingu)

Průchod scénou (Photon scattering)

- při odrazu nebo lomu by se mohla **měnit energie fotonů**
 - foton. mapa by pak obsahovala neekvivalentní záznamy
- zachování konstantní energie fotonu .. **Ruská ruleta**
 - foton se náhodně **šíří dál s původní energií** nebo **zcela zanikne**
 - **rozhodování** mezi:
 - 1. difusním odrazem (D)
 - 2. lesklým odrazem (S, S_M)
 - 3. lomem
 - na každém difusním povrchu: příspěvek do fotonové mapy



Datová struktura fotonové mapy



foton:

- ♦ **poloha** dopadu (float[3])
 - ♦ **směr** dopadu (float[2] nebo komprese do int8[2])
 - ♦ **energie** fotonu (RGB, spektrum nebo RGBE = int8[4])
 - ♦ příznaky pro konstrukci stromu (např. „splitting plane“)
- ♦ fotonová mapa musí být **rychlá** i při **velkém množství záznamů**
- ♦ 10^5 až 10^7 jednotlivých záznamů
 - ♦ operace: **rychlé vyhledávání nejbližších sousedů**
 - K nejbližších nebo všech v daném okolí (poloměr R)
 - ♦ osvědčil se **KD-strom** (binární, data ve všech uzlech)



KD–strom

- ◆ ve fázi konstrukce se jen ukládají záznamy, před použitím je dobré ho **vyvážit**
- ◆ **optimalizace** pro geometrické vyhledávání:
 - ◆ **směr dělení** (splitting plane) se určí podle složky souřadnic s maximálním rozsahem (nebo rozptylem)
 - ◆ uložení v poli – **bez použití ukazatelů !**
- ◆ à la Jensen:
 - ◆ uložení jako halda (potomci mají indexy **$2i$** a **$2i+1$**)
- ◆ à la Hooley („cache-friendly“):
 - ◆ medián se nechává na místě, zbytek jako v quick-sortu



Hledání nejbližších sousedů

- ◆ používá se **halda** pro uložení větví, do kterých jsem ještě nevstoupil
- ◆ ořezávání průchodu:
 - ◆ podle vzdálenosti již nalezeného K-tého nejbližšího fotonu (hledám-li K nejbližších)
 - ◆ podle daného poloměru vyhledávání R



Odhad radiance I

Vyzařovaná **radiance z bodu x**:

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

Vyjádření pomocí **světelného toku**:

$$L_r(x, \omega_o) = \int_{\Omega_x} f_r(x, \omega_i \rightarrow \omega_o) \cdot \frac{\partial^2 \Phi_i(x, \omega_i)}{\partial A_i}$$

Odhad radiance II



Odhad radiance z **fotonové mapy v okolí bodu x**:
(najdu **n** nejbližších fotonů)

$$L_r(x, \omega_o) \approx \sum_{p=1}^n f_r(x, \omega_p \rightarrow \omega_o) \cdot \frac{\Delta \Phi_p(x, \omega_p)}{\Delta A}$$

Při **kruhovém** okolí (n-tý foton má vzdálenost **r**):

$$L_r(x, \omega_o) \approx \frac{1}{\pi r^2} \sum_{p=1}^n f_r(x, \omega_p \rightarrow \omega_o) \cdot \Delta \Phi_p(x, \omega_p)$$



Filtrace ve fotonové mapě

- ◆ pokud se použije menší množství fotonů, průběh odhadu radiance je rozmazaný (... „box filter“)
 - ◆ obzvlášť vadí u kaustické mapy
- ◆ vhodnější filtry zdůrazňují záznamy ve středu prohledávání
 - ◆ kuželový filtr
 - ◆ Gaussovský filtr
 - ◆ **diferenciální kontrola** – pokud se přidáváním dalších (vzdálenějších) fotonů odhad monotónně mění, ukončím přidávání a vrátím aktuální výsledek



Globální zobrazování I

Shrnutí již dříve uvedených vzorců:

$$L_o(x, \omega_o) = L_e(x, \omega_o) + L_r(x, \omega_o)$$

Odražená radiance:

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

Složky funkce odrazivosti:

$$f_r(x, \omega_i, \omega_o) = f_{r,d}(x, \omega_i, \omega_o) + f_{r,s}(x, \omega_i, \omega_o)$$

Globální zobrazování II



Klasifikace přicházející radiance L_i :

$L_{i,l}(x, \omega_i)$ světlo přicházející přímo ze světelných zdrojů L

$L_{i,c}(x, \omega_i)$ kaustika – světlo ze zdrojů koncentrované lesklými odrazy/lomy $L S^+$

$L_{i,d}(x, \omega_i)$ nepřímé světlo odražené minimálně jedenkrát difusně $L S^* D (D|S)^*$

$$L_i(x, \omega_i) = L_{i,l}(x, \omega_i) + L_{i,c}(x, \omega_i) + L_{i,d}(x, \omega_i)$$

Globální zobrazování III



Odražená radiance (vynechán bod odrazu \mathbf{x}):

$$\begin{aligned} L_r(\omega_o) = & \int_{\Omega_x} f_r(\omega_i, \omega_o) \cdot L_{i,l}(\omega_i, \omega_o) \cdot \cos \theta_i \, d\omega_i + \\ & \int_{\Omega_x} f_{r,s}(\omega_i, \omega_o) \cdot (L_{i,c}(\omega_i, \omega_o) + L_{i,d}(\omega_i, \omega_o)) \cdot \cos \theta_i \, d\omega_i + \\ & \int_{\Omega_x} f_{r,d}(\omega_i, \omega_o) \cdot L_{i,c}(\omega_i, \omega_o) \cdot \cos \theta_i \, d\omega_i + \\ & \int_{\Omega_x} f_{r,d}(\omega_i, \omega_o) \cdot L_{i,d}(\omega_i, \omega_o) \cdot \cos \theta_i \, d\omega_i \end{aligned}$$



Přesnost výpočtů

◆ „přesný“ výpočet

- ◆ je-li bod x přímo vidět na obrázku .. nebo
- ◆ je-li vidět přes několik málo lesklých odrazů .. nebo
- ◆ je-li paprsek velmi krátký (eliminace „color bleeding“)

◆ přibližný výpočet

- ◆ v ostatních případech
- ◆ .. jestliže byl paprsek od oka odražen alespoň jednou difusně
- ◆ .. nebo má-li paprsek malou váhu (kumulovaný koeficient odrazu)



Přímé osvětlení

Světlo dopadající přímo ze světelných zdrojů:

$$\int_{\Omega_x} f_r(\omega_i, \omega_o) \cdot L_{i,l}(\omega_i, \omega_o) \cdot \cos \theta_i \, d\omega_i$$

- ◆ v R-T se počítá pomocí stínovacích paprsků
 - ◆ vícenásobné paprsky pro plošné zdroje („Distr. R-T“)
- ◆ přesný výpočet: stínovací paprsky nebo foton. mapa
 - ◆ urychlení .. fotonová mapa obsahuje i „**stínové fotony**“
- ◆ přibližný výpočet: jen podle globání fotonové mapy
 - ◆ bez jakýchkoli sekundárních paprsků



Zrcadlový a lesklý odraz

Nepřímé světlo odražené lesklou složkou BRDF:

$$\int_{\Omega_x} f_{r,s}(\omega_i, \omega_o) \cdot (L_{i,c}(\omega_i, \omega_o) + L_{i,d}(\omega_i, \omega_o)) \cdot \cos \theta_i \, d\omega_i$$

- ◆ klasická Monte-Carlo technika („Distributed R-T“)
 - ◆ přesnost úplně stačí i v náročnějších situacích (přímá viditelnost)
 - ◆ pro uspokojivou přesnost výsledku stačí použít pouze několik odražených paprsků



Kaustika

Světlo ze zdroje koncentrované na matném povrchu:

$$\int_{\Omega_x} f_{r,d}(\omega_i, \omega_o) \cdot L_{i,c}(\omega_i, \omega_o) \cdot \cos \theta_i \, d\omega_i$$

- ◆ přesný výpočet: kaustická fotonová mapa
 - ◆ tato mapa obsahuje velkou koncentraci fotonů, přesnost je tedy velká (ostrá kaustika)
- ◆ přibližný výpočet: podle globání fotonové mapy



Mnohonásobný měkký odraz

Světlo odražené mnohokrát difusně:

$$\int_{\Omega_x} f_{r,d}(\omega_i, \omega_o) \cdot L_{i,d}(\omega_i, \omega_o) \cdot \cos \theta_i \, d\omega_i$$

- ◆ přesný výpočet: „Distributed R-T“ (Monte-Carlo)
 - ◆ optimalizace vzorkování podle globální fotonové mapy (znám směry dopadů fotonů v okolí daného bodu)
 - ◆ další urychlení: „Irradiance caching“ (Ward 1988)
- ◆ přibližný výpočet: podle globální fotonové mapy




Vzorkování Metropolis

- ◆ cíle a aplikace realistického zobrazování
- ◆ historie, přehled používaných přístupů
 - ◆ Ray-tracing, radiační metody
- ◆ teoretické základy – zobrazovací rovnice
 - ◆ souhlas starších metod s teorií (fyzikou)
- ◆ metody založené na zobrazovací teorii
 - ◆ Monte-Carlo zobrazování (paprsky, „unbiased“)
 - ◆ hybridní metody (efektivita)
 - ◆ Photon-mapping
 - ◆ **Metropolis sampling**
 - ◆ ADRRS (Vorba, Křivánek, SIGGRAPH 2016)



Motivace Metropolis



Jen **málo** pravděpodobné cesty světla mohou přispět k výslednému obrázku..

Motivace Metropolis



“Veach door”





Metropolis vzorkování

- ◆ **Nicholas Metropolis** et al, 1953, výpočetní fyzika
- ◆ vzorkování podle dané funkce f v obtížných podmínkách
- ◆ generuje posloupnost vzorků $\{x_i\}$ s hustotou úměrnou f

stavový prostor Ω $f : \Omega \rightarrow \mathbb{R}^+$

$$I(f) = \int_{\Omega} f(x) d\Omega \quad f_{pdf} = f / I(f)$$

generování vzorků $X = \{x_i\}$ $x_i \sim f_{pdf} \propto f$

Přitom není potřeba počítat $I(f)$ ani f_{pdf} !



Základní algoritmus

- ◆ **Markovův řetězec** vzorků: x_i závisí jen na x_{i-1}
- ◆ generátor nového vzorku – „**mutate()**“
- ◆ pravděpodobnost **schválení** – „**accept()**“
 - ✚ zajišťuje správnou a stacionární distribuci x_i

```
State x, x0, result[N];
```

```
x = x0;
```

```
for ( i = 0; i < N; i++ ) {  
    // generate next sample  
    State x' = mutate( x );  
    float a = accept( x, x' );  
    if ( random() < a ) x = x';  
    result[i] = x;  
}
```



Rozšířený algoritmus

- ◆ vzorkuje i oblasti s **nízkou hodnotou $f(x)$**
- ◆ v limitě má stejný výsledek (distribuci)

```
State x, x0, result[2*N];
float weight;           // standard sample weight
float weights[2*N];    // result weights

x = x0;
for ( i = 0; i < 2*N; ) {
    // generate next sample
    State x' = mutate( x );
    float a = accept( x, x' );
    result[i] = x; weights[i++] = (1-a) * weight;
    result[i] = x'; weights[i++] = a * weight;
    if ( random() < a ) x = x';
}
```




Mutace, přechody, schvalování

- ◆ hustota pravděpodobnosti **přechodu od x k x'**
 - ◆ je dána mutačním předpisem („`mutate()`“)

$$T(x \rightarrow x')$$

- ◆ **pravděpodobnost schválení** tohoto přechodu
 - ◆ musí se spočítat (pozor na chyby!)
 - ◆ je-li určena správně, zajišťuje správnou distribuci výsledků

$$a(x \rightarrow x')$$



Pravděpodobnost schválení $a()$

- ♦ podmínka **stacionární pravděpodobnosti výsledku $f(x)$**

$$f(x) T(x \rightarrow x') a(x \rightarrow x') = f(x') T(x' \rightarrow x) a(x' \rightarrow x)$$

- ♦ efektivní volba $a()$:

$$a(x \rightarrow x') = \min \left(1, \frac{f(x') T(x' \rightarrow x)}{f(x) T(x \rightarrow x')} \right)$$



Volba přechodů

- ◆ pravděpodobnost schválení by měla být co nejvyšší
 - ◆ lépe prozkoumáme stavový prostor
 - ◆ minimalizujeme korelace (alias v grafice)
- ◆ preferujeme přechody, které budou spíše schváleny
 - ◆ tj. přechody mířící do oblastí s větším $f(\mathbf{x})$
- ◆ **adaptivní metody mutace**
 - ◆ můžeme měnit přechodovou funkci na základě zkušenosti
- ◆ musíme jen umět spočítat přechodové hustoty $T(\dots)$



Speciální přechodové funkce

- jestliže je přechodová funkce symetrická

$$\forall a, b \quad T(a \rightarrow b) = T(b \rightarrow a)$$

- ➔ pak je akceptance

$$\alpha(x \rightarrow x') = \min\left(1, \frac{f(x')}{f(x)}\right)$$

- **náhodná procházka Metropolis** (Brownův pohyb):

$$T(x \rightarrow x') = T(|x - x'|)$$



Spojité 1D příklad

- stavový prostor a kritérium: $\Omega = \mathbb{R}$

$$f^1(x) = \begin{cases} (x - 1/2)^2 & 0 \leq x \leq 1 \\ 0 & \text{otherwise} \end{cases}$$

- chceme generovat vzorky podle f^1 ..

- nejjednodušší přechodová funkce a hustota:

$$mutate_1(x) = rnd()$$

$$T_1(x \rightarrow x') = 1$$

- .. je to náhodná procházka Metropolis



Jiná přechodová funkce

- ◆ přechodová funkce a hustota (à la Brownův pohyb):

$$\mathit{mutate}_2(x) = x + 0.1 \cdot (\mathit{rnd}() - 0.5)$$

$$T_2(x \rightarrow x') = \begin{cases} 10 & : \quad |x - x'| \leq 0.05 \\ 0 & : \quad \mathit{otherwise} \end{cases}$$

- ◆ .. také zde se jedná o náhodnou procházku Metropolis (pro vysoké hodnoty $f(\mathbf{x})$ odmítá „klesat“)



Konvergence

- ◆ samostatná přechodová funkce **mutate₁**
 - konverguje, ale pomalu
- ◆ kombinace **mutate₁** a **mutate₂** (random: 10%, 90%)
 - ◆ konverguje velmi dobře
- ◆ samotná přechodová funkce **mutate₂**
 - ◆ má tendenci „utéci“ do jedné větve a už se nevrátit
 - ◆ potřebuje jednou za čas začít od začátku (výběrem nového \mathbf{x}_0)



Aplikace v M-C kvadratuře

- ♦ určitý integrál ze součinu dvou funkcí:

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

- ♦ standardní Monte-Carlo přístup („Importance sampling“)

$$I \approx \frac{1}{N} \sum_{i=1}^N \frac{f(x_i) \cdot g(x_i)}{p(x_i)}$$

where $x_i \sim p(x)$ (arbitrary PDF)



Metropolis kvadratura

- ◆ **Metropolis přístup** používá jednu z funkcí jako hustotu pravděpodobnosti pro vzorkování \mathbf{x}_i :

$$I \approx \left[\frac{1}{N} \sum_{i=1}^N g(x_i) \right] \cdot I(f)$$

where $x_i \sim f_{pdf}(x)$

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

... integrál té funkce bychom měli znát:

- ◆ konvoluce obrazu (jádro konvoluce)
- ◆ BRDF při šíření světla odrazem



Metropolis rendering

- stavový prostor: prostor **náhodných procházek** potenciálně přenášejících světlo od zdroje do receptoru
- inicializace: hledání efektivních cest světla
 - obousměrný Path-tracing
 - minimalizace zkreslení (počátečních několik mutací nezapočítávám do výsledku)
- různé typy mutací
 - perturbace **kamery**: $(L|D)DS^*E$ nahradím (stejná délka)
 - perturbace **kaustiky**: $(L|D)S^*DE$ nahradím
 - **delší řetězce**: např. $(L|D)DS^*DS^*DE$ nahrazuji



Výběr mutací

- velká pravděpodobnost schválení mutace
 - jinak je posloupnost cest hodně konstantní (\rightarrow šum)
- preferovat rozsáhlé změny cesty světla
 - jinak jsou vzorky dost podobné (\rightarrow šum)
 - modifikace delšího úseku cesty světla najednou
- ergodicita
 - konvergence ke správnému rozdělení bez ohledu na X_0
 - nesmí se mi algoritmus „zaseknout“ v nějaké oblasti..
- často modifikovat pozici na kameře (čočka, průmětna)



Osvědčené mutace

- **perturbace na kameře (objektivu)**
 - ◆ smažu a nahradím celou cestu $(L|D)DS^*E$
 - ◆ o kousek **náhodně přemístím** pozici na čočce a/nebo v průmětně
 - ◆ k regeneraci úseku cesty se použije Path-tracing
- ◆ **perturbace kaustiky**
 - ◆ podobná jako na kameře, ale poslední odraz je difusní
 - ◆ nahrazení cesty $(L|D)S^*DE$
 - ◆ první smazaný paprsek se odchýlí o **malý náhodný úhel** (exponenciální rozdělení)



Osvědčené mutace

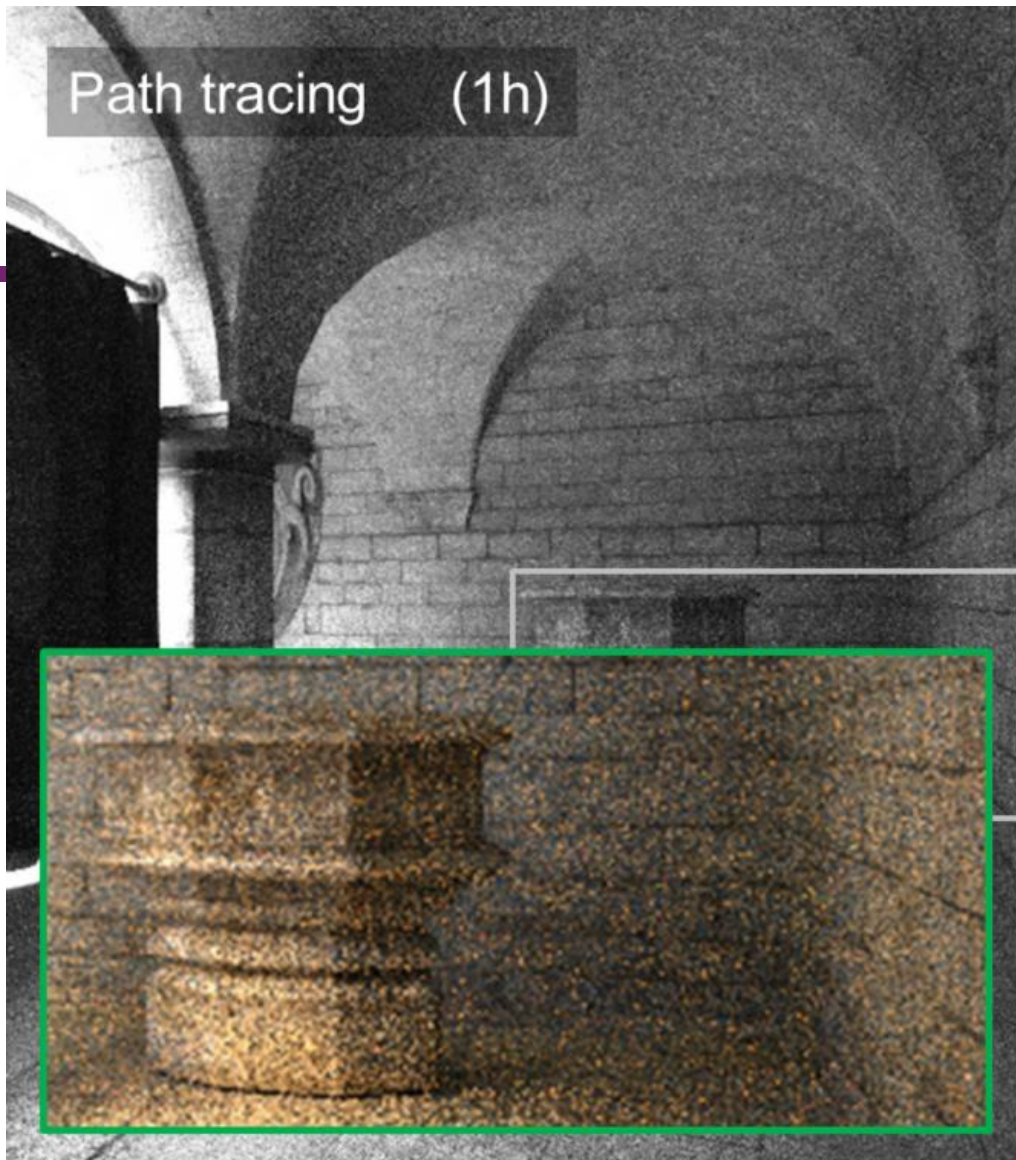
- perturbace **delších řetězců**
 - ◆ smažu a nahradím cesty typu **(L|D)DS*DS*E**
 - ◆ na každém difusním odrazu trochu pozměním směr paprsku k následující lesklé ploše
 - ...
- ◆ náhodný výběr konkrétní mutace
 - ◆ zachovávat maximální variabilitu typu mutace
 - ◆ proměnlivost délky mutovaného řetězce

ADRRS metoda (SIGGRAPH 2016)




- ◆ cíle a aplikace realistického zobrazování
- ◆ historie, přehled používaných přístupů
 - ◆ Ray-tracing, radiační metody
- ◆ teoretické základy – zobrazovací rovnice
 - ◆ souhlas starších metod s teorií (fyzikou)
- ◆ metody založené na zobrazovací teorii
 - ◆ Monte-Carlo zobrazování (paprsky, „unbiased“)
 - ◆ hybridní metody (efektivita)
 - ◆ Photon-mapping
 - ◆ Metropolis sampling
 - ◆ **ADRRS (Vorba, Křivánek, SIGGRAPH 2016)**

Path tracing (1h)




Our ADRRS + path guiding (1h)
in path tracing




Adjoint-Driven Russian Roulette and Splitting in Light Transport Simulation

- ◆ Jiří Vorba, Jaroslav Křivánek, SIGGRAPH 2016

Russian roulette




Compensation



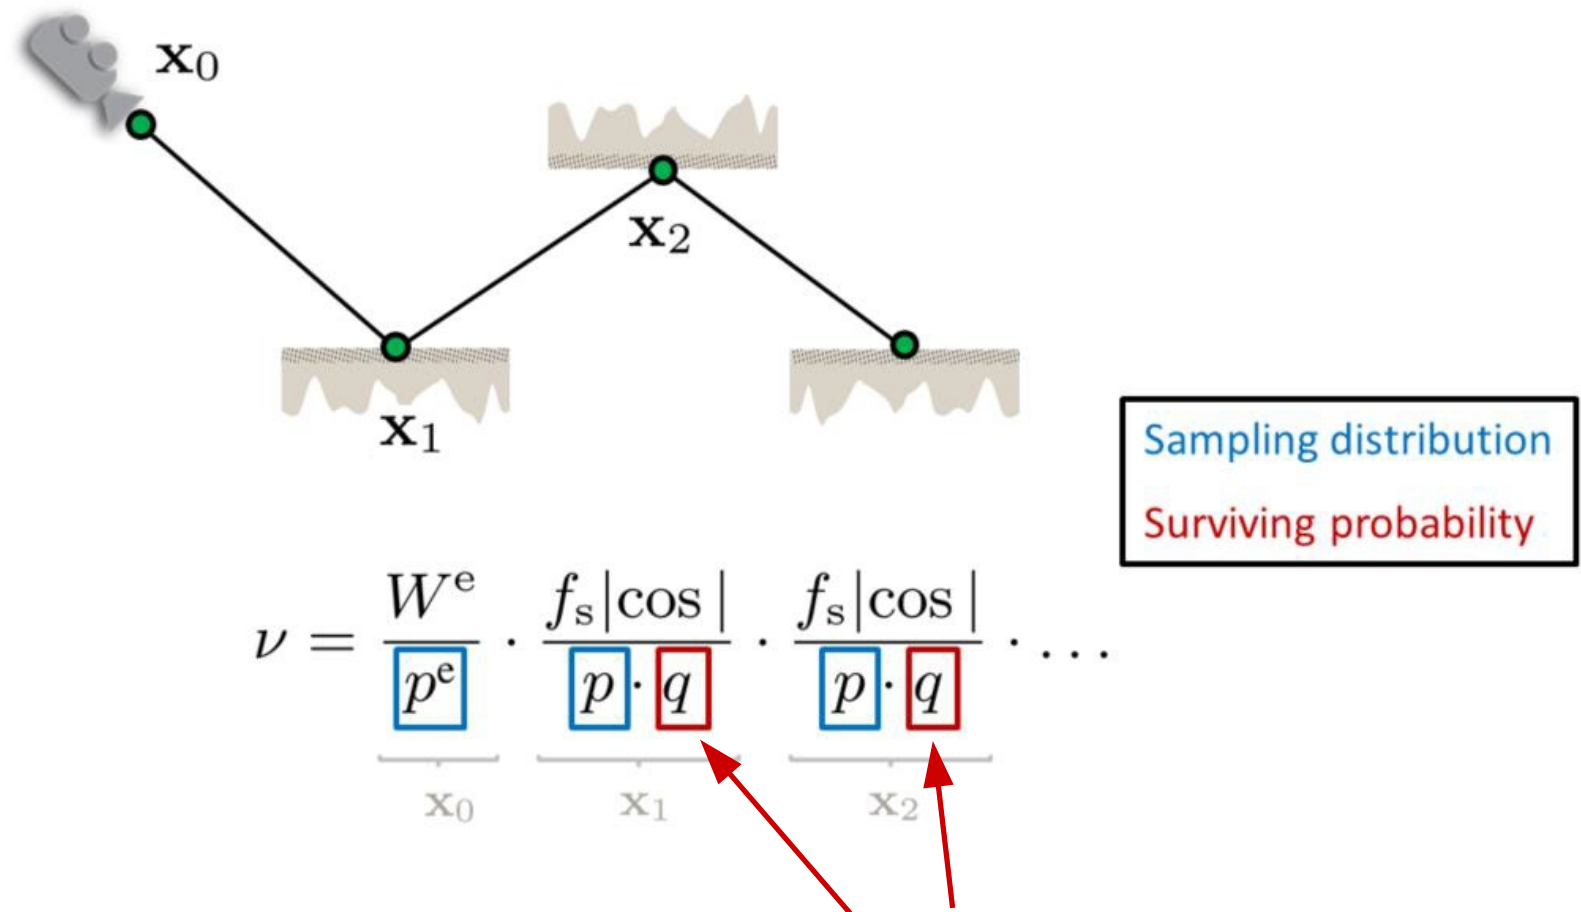
$$\frac{\nu}{q}$$

The throughput = path weight




$$\nu = \underbrace{\frac{W^e}{p^e}}_{x_0} \cdot \underbrace{\frac{f_s |\cos|}{p \cdot q}}_{x_1} \cdot \underbrace{\frac{f_s |\cos|}{p \cdot q}}_{x_2} \cdot \dots$$

Sampling & surviving probabilities



Russian roulette only changes surviving probabilities


Surviving probability by Arvo & Kirk



$$q = \frac{\nu}{\text{threshold}}$$

[Arvo & Kirk 1990]


Surviving probability by Jensen



$$q = \text{albedo}$$


[Jensen 2001]

Splitting (Distributed ray-tracing)



Cook et al. 1984

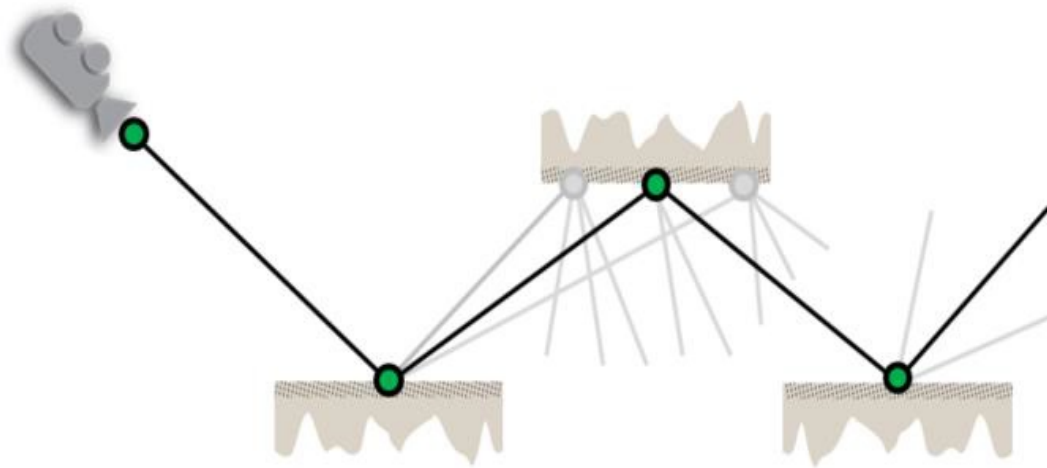
Correcting the path weight



$$\nu = \frac{W^e}{p^e} \cdot \frac{f_s |\cos|}{\underbrace{p \cdot q}_{X_1}} \cdot \frac{f_s |\cos|}{\underbrace{p \cdot q}_{X_2}} \cdot \dots$$


splitting factor

Plain path tracing




$$q = 1$$

Unwanted exponential branching



$$q = 3$$


Split factor by Szirmay-Kalos & Antal



$$q = H(\text{albedo, roughness})$$

[Szirmay-Kalos and Antal 2001]

Russian roulette + Splitting




RR: $q < 1$


Split: $q > 1$

[Szirmay-Kalos and Antal 2001]


Issue: premature terminating




Our approach: promising paths survive



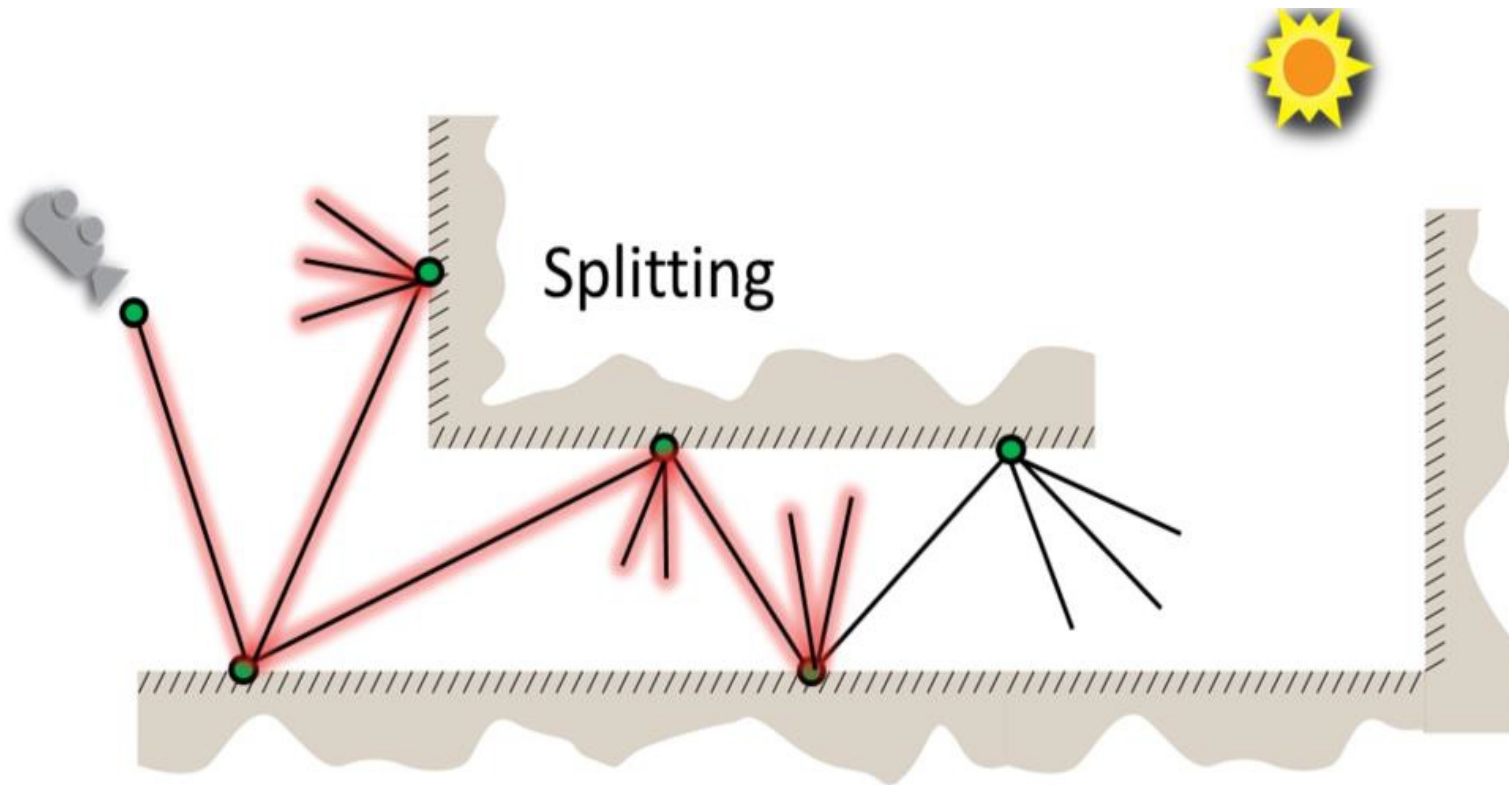
Still terminating useless paths




Splitting is good in general ..




.. but can be too expensive



Our method splits efficiently




Our ADRRS computes q in each vertex



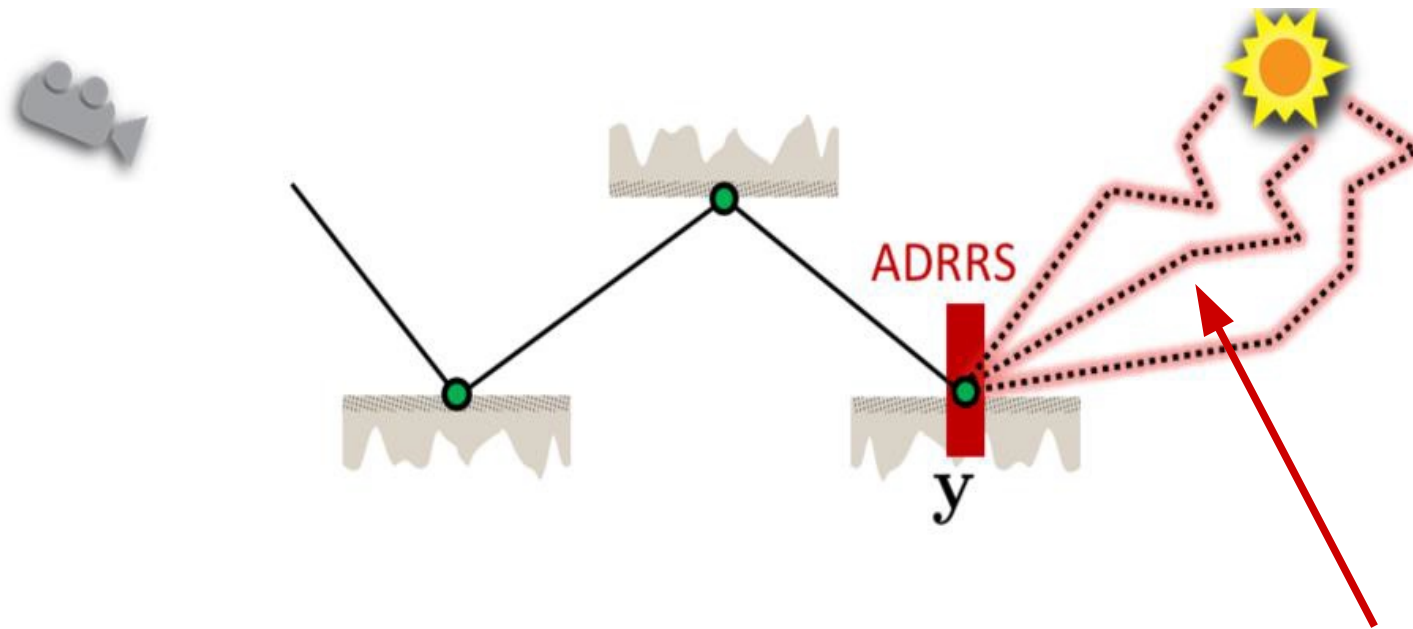
$$q(\mathbf{y}) =$$

Considering both history of the path..



$$q(\mathbf{y}) = \frac{\nu(\mathbf{y})L(\mathbf{y})}{I}$$


.. and its future (reflected radiance)



$$q(\mathbf{y}) = \frac{\nu(\mathbf{y})L(\mathbf{y})}{I}$$

all possible paths


Unbiased estimate of pixel value I



$$q(\mathbf{y}) = \frac{\nu(\mathbf{y})L(\mathbf{y})}{I}$$

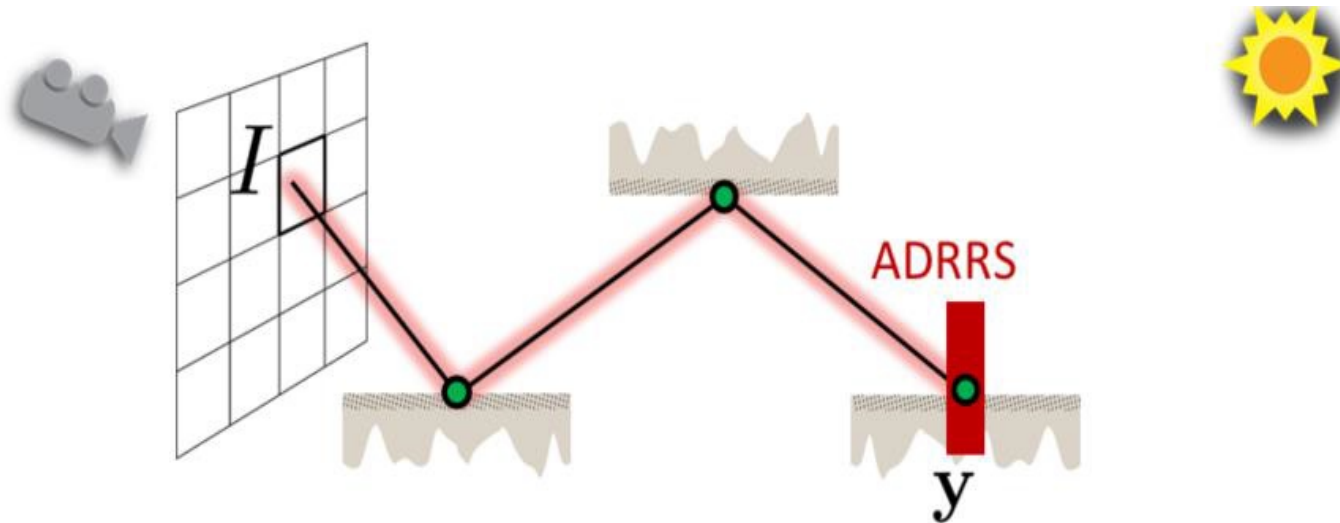


Path weight under ADRRS



$$q(\mathbf{y}) = \frac{\nu(\mathbf{y})L(\mathbf{y})}{I}$$

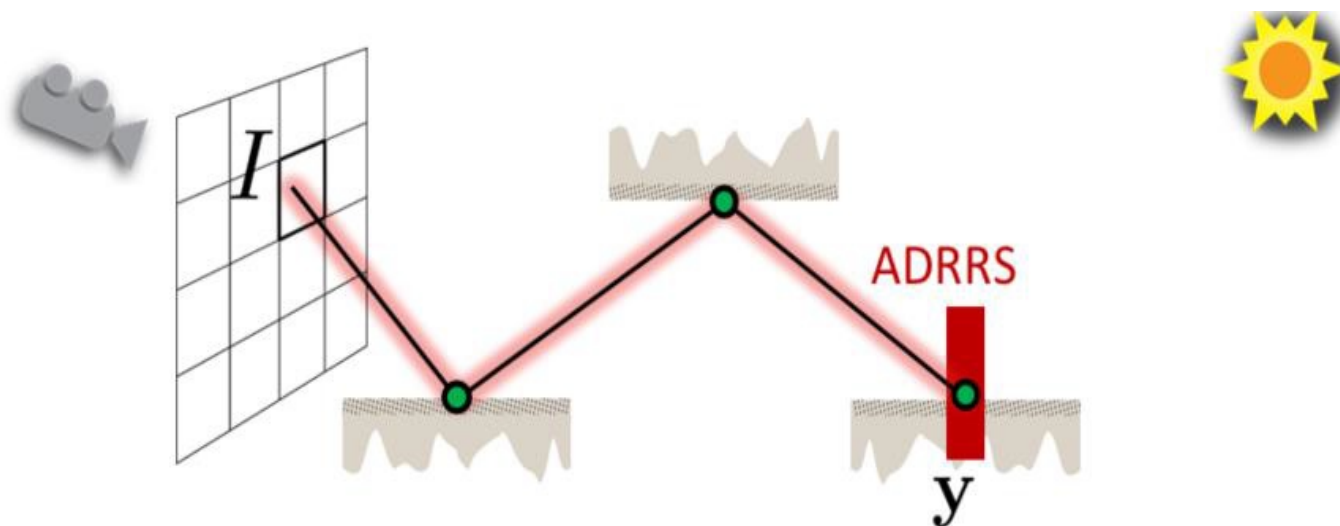
Path weight changes in ADRRS



$$q(\mathbf{y}) = \frac{\nu(\mathbf{y})L(\mathbf{y})}{I}$$




Division by $q(\mathbf{y})$, in both cases




$$\frac{\nu(\mathbf{y})}{q(\mathbf{y})}$$

Resulting into an invariant ratio

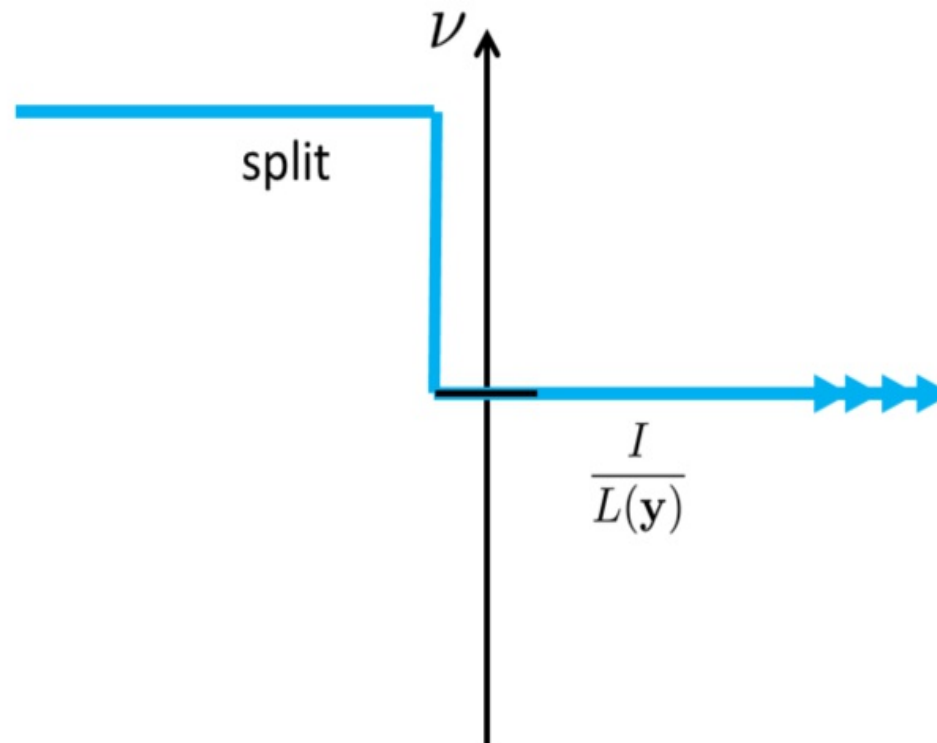


$$q(\mathbf{y}) = \frac{\nu(\mathbf{y})L(\mathbf{y})}{I} \quad \frac{\nu(\mathbf{y})}{q(\mathbf{y})} = \boxed{\frac{I}{L(\mathbf{y})}}$$


Simple path-weight chart



Higher incoming weight \Rightarrow split

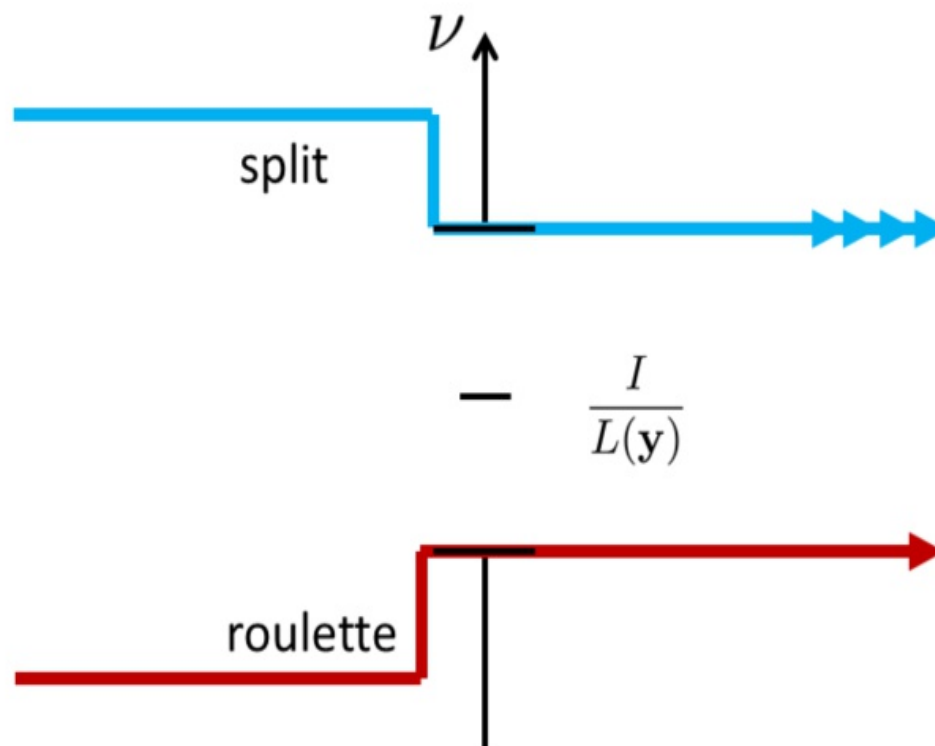


Lower incoming weight \Rightarrow roulette






Weight window





Pass through option

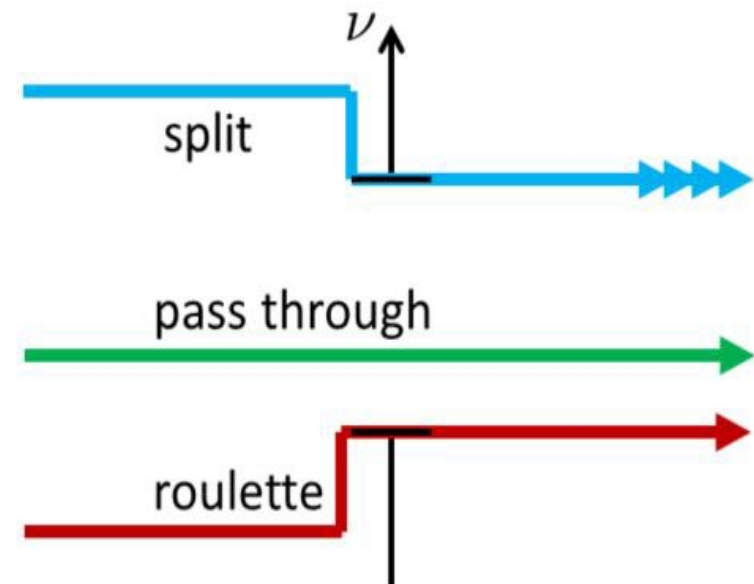


Nothing new in computational physics


A standard technique in neutron transport



(MCNP package, ..)

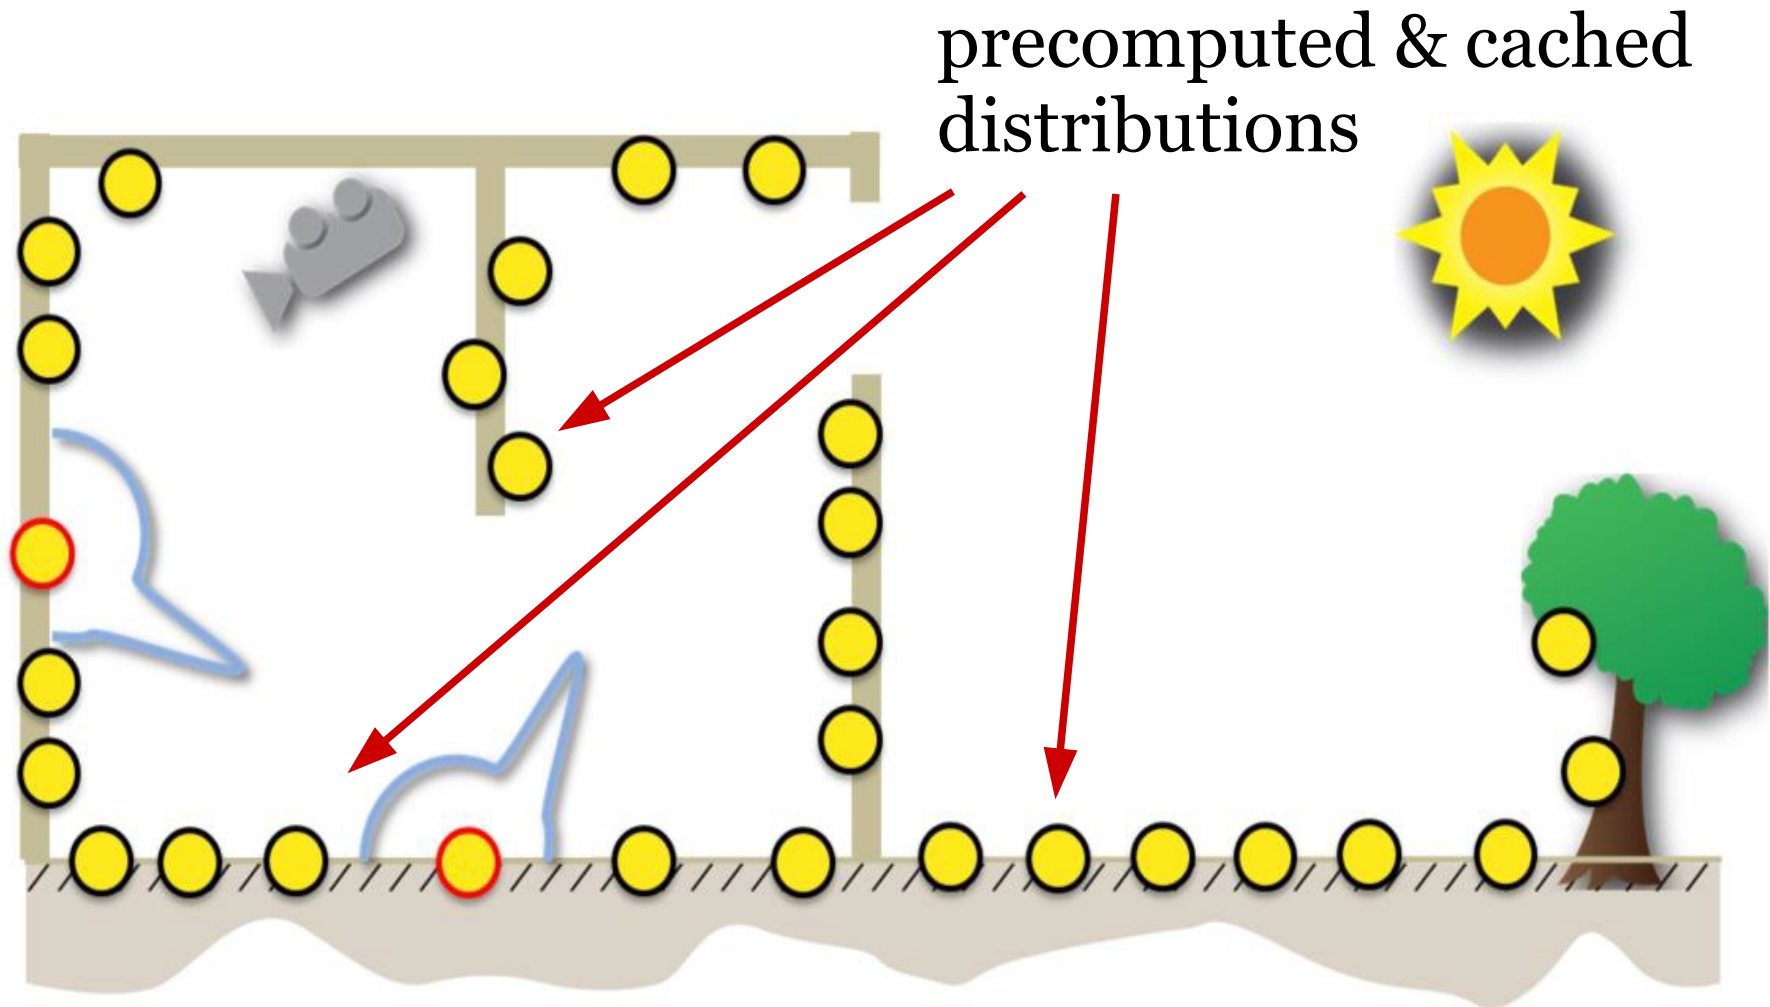


Estimates are needed..





$$\frac{I}{L(\mathbf{y})}$$

Our method “Path guiding“!




Precomp. estimate the radiance field






Pixel value estimates



Reflectance radiance estimate



Irradiance
and **albedo** at y




$$L(\mathbf{y})$$

good enough for diffuse materials..



.. but can be too expensive


Distribution,
irradiance
and **albedo** at x



$$L(\mathbf{y})$$


better for glossy surfaces

Example with glossy surface




$$L(\mathbf{y})$$


Irradiance only



Directional estimate




Importance sampling



$$p_{zv}(\mathbf{x}) \propto L_i(\mathbf{x}) f_s(\mathbf{x}) |\cos|$$

zero-variance pdf !

Sampling based on local information




Material sampling

$$p_{zv}(\mathbf{x}) \propto L_i(\mathbf{x}) \boxed{f_s(\mathbf{x}) |\cos|}$$

$p(\mathbf{x})$

Path guiding knows incoming radiance




Path guiding


$$p_{zv}(\mathbf{x}) \propto \frac{L_i(\mathbf{x}) f_s(\mathbf{x}) |\cos|}{p(\mathbf{x})}$$



Splitting factor at y





Compensating undersampling ...



$$q(\mathbf{y}) = \frac{p_{zv}(\mathbf{x})}{p(\mathbf{x})}$$

... and oversampling as well




$$q(\mathbf{y}) = \frac{p_{zv}(\mathbf{x})}{p(\mathbf{x})}$$

Natural behavior of ADRRS




$$q(\mathbf{y}) = \frac{p_{zV}(\mathbf{x})}{p(\mathbf{x})}$$

Path tracing: need to estimate I , $L(\mathbf{y})$



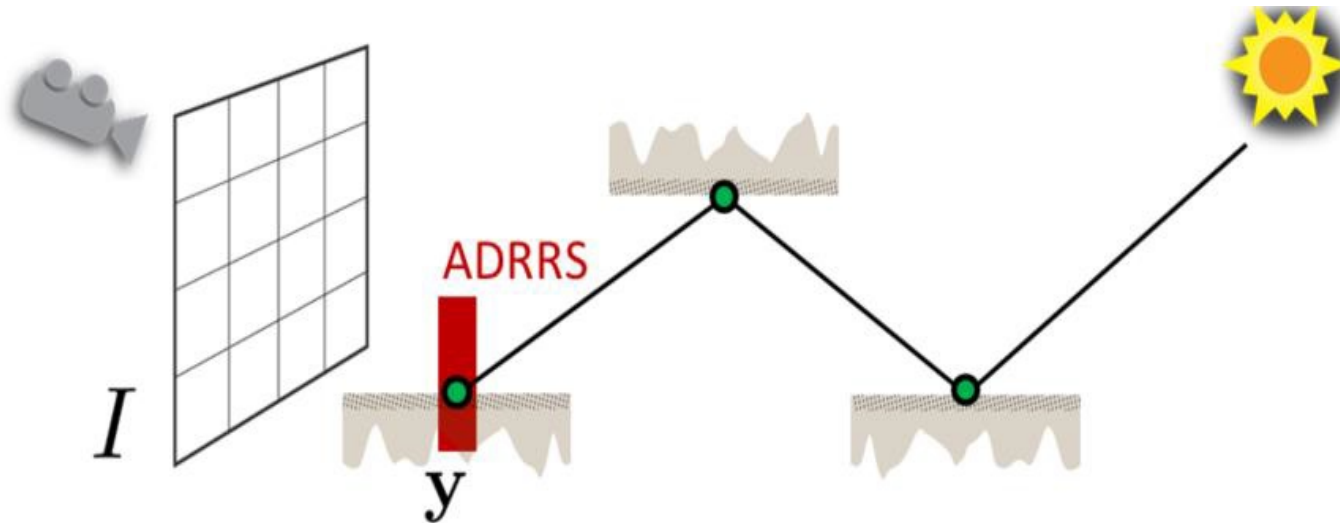
$$\frac{I}{L(\mathbf{y})}$$

Photon tracing: average contribution I



$$\frac{I}{L(y)}$$

Photon tr.: different adjoint quantity




visual importance
from the camera


$$\frac{I}{W(\mathbf{y})}$$

Photon mapping (1h)

Plain




+ our ADRRS



Path guiding



+ our ADRRS



Path tracing (1h)





Plain

+ our ADRRS

Path guiding

+ our ADRRS



<http://cgg.mff.cuni.cz/~jirka/papers/2016/adrrs/>

Computer
Graphics
Charles
University



Literatura – knihy



- ◆ Andrew Glassner: ***Principles of Digital Image Synthesis***, Morgan Kaufmann, 1995
- ◆ Henrik Wann Jensen: ***Realistic Image Synthesis Using Photon Mapping***, A K Peters, 2001
- ◆ Matt Pharr, Greg Humphreys: ***Physically Based Rendering, 2nd Edition: From Theory To Implementation***, Morgan Kaufmann, 2010
- ◆ Philip Dutre, Kavita Bala, Philippe Baekert: ***Advanced Global Illumination***, A K Peters, 2006

Literatura



- ◆ Eric Veach, Leonidas J. Guibas: ***Optimally Combining Sampling Techniques for Monte Carlo Rendering***, SIGGRAPH'95 Proceedings
- ◆ Eric Lafortune: ***Mathematical Models and Monte Carlo Algorithms for Physically Based Rendering***, PhD thesis, KU Leuven, 1996
- ◆ Eric Veach: ***Robust Monte Carlo Methods for Light Transport Simulation***, PhD Thesis, 1997
- ◆ Henrik Wann Jensen et al.: ***A Practical Guide to Global Illumination using Photon Mapping***, SIGGRAPH 2002 Course