

渲染方程的概率解释

曹陆铖 重庆大学大数据与软件学院

2024 年 12 月 12 日

在勒贝格积分的框架下，渲染方程可以表示为：

$$L_o(x, \omega_o) = L_e(x, \omega_o) + \int_{\Omega} f_r(x, \omega_i, \omega_o) L_i(x, \omega_i) (\omega_i \cdot n) d\lambda(\omega_i).$$

1 各项解释

- $L_o(x, \omega_o)$: 在点 x 处，沿着出射方向 ω_o 的出射辐射亮度 (Outgoing Radiance)。
- $L_e(x, \omega_o)$: 在点 x 处，沿着方向 ω_o 的自发辐射亮度 (Emitted Radiance)。对于非发光表面，此项通常为零。
- 积分符号 \int_{Ω} : 表示在半球 Ω 上对所有可能的入射方向 ω_i 的勒贝格积分。 Ω 是单位半球面 \mathbb{S}_+^2 ，即以表面法线 n 为基准的所有朝向上半球的方向集合。

$$\Omega = \mathbb{S}_+^2 = \{\omega_i \in \mathbb{R}^3 \mid \|\omega_i\| = 1, \omega_i \cdot n \geq 0\}$$

- $f_r(x, \omega_i, \omega_o)$: 双向反射分布函数 (BRDF)，描述了入射方向 ω_i 的光如何被表面反射到出射方向 ω_o 。
- $L_i(x, \omega_i)$: 在点 x 处，沿着入射方向 ω_i 的入射辐射亮度 (Incoming Radiance)。
- $(\omega_i \cdot n)$: 入射方向与表面法线的点积，表示入射光线与表面法线之间的夹角余弦。
- $d\lambda(\omega_i)$: 这里的测度 λ 是半球面上的面积测度。

2 使用大数定律进行蒙特卡洛估计

在渲染方程的基础上，为了对反射光进行有效的采样，我们需要引入概率论中的随机变量概念。随机变量 X 是一个从样本空间到目标空间的 measurable 函数。

在本情境下，给定一个定义在概率空间 $(S, \mathcal{F}, \mathbb{P})$ 上的随机变量 $X: S \rightarrow \Omega$ ，其中 Ω 是半球方向空间， X 将概率测度 \mathbb{P} 推到 Ω 上，从而定义出推前测度 μ :

$$\mu(B) = \mathbb{P}(X^{-1}(B)) \quad \forall B \in \mathcal{B}(\Omega).$$

如果该推前测度 μ 关于半球上的面积测度 λ 是绝对连续的，那么根据 Radon-Nikodym 定理，存在一个概率密度函数 $p(\omega_i)$ 满足：

$$d\mu(\omega_i) = p(\omega_i) d\lambda(\omega_i).$$

给定可测函数

$$f(\omega_i) = f_r(x, \omega_i, \omega_o) L_i(x, \omega_i)(\omega_i \cdot n),$$

假设 $\mathbb{E}_\mu \left[\left| \frac{f(\omega_i)}{p(\omega_i)} \right| \right] < \infty$ 。

定义随机变量

$$Y(\omega_i) := \frac{f(\omega_i)}{p(\omega_i)}.$$

则根据期望的定义，有

$$\mathbb{E}_\mu[Y] = \int_{\Omega} Y(\omega_i) d\mu(\omega_i) = \int_{\Omega} \frac{f(\omega_i)}{p(\omega_i)} p(\omega_i) d\lambda(\omega_i) = \int_{\Omega} f(\omega_i) d\lambda(\omega_i).$$

现从分布 μ 独立同分布抽样 X_1, X_2, \dots, X_N ，其中每个 X_i 都有密度 p ，并构造蒙特卡洛估计量

$$\hat{I}_N := \frac{1}{N} \sum_{i=1}^N \frac{f(X_i)}{p(X_i)}.$$

由于 X_i 是 i.i.d. 随机变量，并且 $\mathbb{E}_\mu[|Y|] < \infty$ ，强大数定律 (Strong Law of Large Numbers) 保证了随着样本数 $N \rightarrow \infty$ ，有

$$\hat{I}_N \xrightarrow{\text{a.s.}} \mathbb{E}_\mu[Y] = \int_{\Omega} f(\omega_i) d\lambda(\omega_i),$$

即以概率 1 收敛于原积分值。

3 通过方差选择密度函数 p

蒙特卡洛估计的误差通常用方差来衡量。设

$$\text{Var}_\mu(Y) = \mathbb{E}_\mu[Y^2] - (\mathbb{E}_\mu[Y])^2.$$

由中心极限定理知，当 N 足够大时，

$$\sqrt{N}(\hat{I}_N - \mathbb{E}_\mu[Y]) \approx \mathcal{N}(0, \text{Var}_\mu(Y)),$$

即估计量 \hat{I}_N 的标准差约为 $\sqrt{\text{Var}_\mu(Y)/N}$ 。因此，为了减少蒙特卡洛估计的方差，我们希望通过恰当地选择 $p(\omega_i)$ 来尽可能降低 $\text{Var}_\mu(Y)$ 。

具体来说，观察

$$Y(\omega_i) = \frac{f(\omega_i)}{p(\omega_i)}.$$

方差最小化的直观策略是使 $Y(\omega_i)$ 尽可能趋于常量，即波动尽可能小。这可以通过令 $p(\omega_i)$ 与 $|f(\omega_i)|$ 成比例来实现。例如，如果选择

$$p(\omega_i) \propto |f(\omega_i)|,$$

则 $\frac{f(\omega_i)}{p(\omega_i)}$ 将近似为一常量 (在理想情况下恰为常量)，从而最小化方差。

在实际应用中，这一思想即为**重要性采样 (Importance Sampling)**。虽然精确选择 $p(\omega_i)$ 为与 $|f(\omega_i)|$ 成比例在很多情况下不可行或成本过高，但人们通常会根据场景中的已知信息或启发式方法设计 p 来接近这一理想分布，从而降低方差，提高蒙特卡洛估计的收敛效率。