

# 基于机器学习的三维场景高度真实感绘制方法综述\*

赵烨梓<sup>1,2</sup>, 王璐<sup>1,2</sup>, 徐延宁<sup>1,2</sup>, 曾峰<sup>1,2</sup>, 葛亮昇<sup>1,2</sup>, 朱君秋<sup>1,2</sup>, 徐子林<sup>1,2</sup>, 赵钰<sup>1,2</sup>, 孟祥旭<sup>1,2</sup>



<sup>1</sup>(山东大学 软件学院, 山东 济南 250101)

<sup>2</sup>(数字媒体技术教育部工程研究中心, 山东 济南 250101)

通信作者: 王璐, E-mail: [luwang\\_hcivr@sdu.edu.cn](mailto:luwang_hcivr@sdu.edu.cn); 徐延宁, E-mail: [xyn@sdu.edu.cn](mailto:xyn@sdu.edu.cn)

**摘要:** 目前, 电影、动漫、游戏等产业对真实感绘制的需求越来越高, 而三维场景高度真实感绘制通常需要耗费大量的计算时间和存储空间来计算全局光照, 如何在保证绘制质量的前提下提升绘制速度依然是图形学领域面临的核心和热点问题之一。数据驱动的机器学习方法开辟了一种新的研究思路, 近年来研究者将多种高度真实感绘制方法映射为机器学习问题, 从而大大降低了计算成本。总结分析了近年来基于机器学习的高度真实感绘制方法的研究进展, 具体包括: 基于机器学习的全局光照优化计算方法、基于深度学习的物理材质建模方法、基于深度学习的参与性介质优化绘制方法、基于机器学习的蒙特卡洛降噪方法等。详细论述了各种绘制方法与机器学习方法的映射思路, 归纳总结了网络模型以及训练数据集的构建方式, 并在绘制质量、绘制时间、网络能力等多个方面开展了对比分析。最后, 本文提出了机器学习和真实感绘制相结合的可能思路和未来展望。

**关键词:** 真实感绘制; 机器学习; 全局光照; 基于物理的材质模型; 蒙特卡洛降噪

**中图法分类号:** TP309

中文引用格式: 赵烨梓, 王璐, 徐延宁, 曾峰, 葛亮昇, 朱君秋, 徐子林, 赵钰, 孟祥旭. 基于机器学习的三维场景高度真实感绘制方法综述. 软件学报, 2022, 33(1): 356–376. <http://www.jos.org.cn/1000-9825/6334.htm>

英文引用格式: Zhao YZ, Wang L, Xu YN, Zeng Z, Ge LS, Zhu JQ, Xu ZL, Zhao Y, Meng XX. State-of-the-art Survey on Photorealistic Rendering of 3D Scenes Based on Machine Learning. Ruan Jian Xue Bao/Journal of Software, 2022, 33(1): 356–376 (in Chinese). <http://www.jos.org.cn/1000-9825/6334.htm>

## State-of-the-art Survey on Photorealistic Rendering of 3D Scenes Based on Machine Learning

ZHAO Ye-Zi<sup>1,2</sup>, WANG Lu<sup>1,2</sup>, XU Yan-Ning<sup>1,2</sup>, ZENG Zheng<sup>1,2</sup>, GE Liang-Sheng<sup>1,2</sup>, ZHU Jun-Qiu<sup>1,2</sup>, XU Zi-Lin<sup>1,2</sup>, ZHAO Yu<sup>1,2</sup>, MENG Xiang-Xu<sup>1,2</sup>

<sup>1</sup>(School of Software, Shandong University, Jinan 250101, China)

<sup>2</sup>(Engineering Research Center of Digital Media Technology, Ministry of Education, Jinan 250101, China)

**Abstract:** Nowadays, the demand for photorealistic rendering in the movie, anime, game, and other industries is increasing, and the highly realistic rendering of 3D scenes usually requires a lot of calculation time and storage to calculate global illumination. How to ensure the quality of rendering on the premise of improving drawing speed is still one of the core and hot issues in the field of graphics. The data-driven machine learning method has opened up a new approach. In recent years, researchers have mapped a variety of highly realistic rendering methods to machine learning problems, thereby greatly reducing the computational cost. This article summarizes and analyzes the research progress of highly realistic rendering methods based on machine learning in recent years, including: global illumination optimization calculation methods based on machine learning, physical material modeling methods based on deep learning, and participatory media drawing method optimization based on deep learning, Monte Carlo denoising method based on machine learning, etc. This article discusses the mapping ideas of various drawing methods and machine learning methods in detail, summarizes the construction methods of network models and training data sets, and conducts comparative analysis on drawing quality, drawing time, network capabilities, and other aspects. Finally, this article proposes possible ideas and future prospects for the combination of machine learning and realistic rendering.

**Key words:** photorealistic rendering; machine learning; global illumination; physics-based material model; Monte Carlo noise reduction

\* 基金项目: 国家重点研发计划(2020YFB1708900); 国家自然科学基金(61872223); 山东省自然科学基金(ZR2020LZH016)

收稿时间: 2020-08-20; 修改时间: 2020-11-06, 2021-01-03; 采用时间: 2021-03-22; jos 在线出版时间: 2021-04-20

三维场景高度真实感绘制是通过计算机模拟光线在 3D 场景中传播的物理过程, 将设计人员创作的由视点、光源、三维几何、动画、材质等组成的镜头转化为高度真实感的连续帧画面。全局光照模拟了光线在场景中传播的过程, 对绘制真实感具有至关重要的作用。而计算全局光照的核心在于绘制方程<sup>[1]</sup>, 该方程计算光束和三维物体的交互过程中的能量传递, 具有全局性、递归性等特点, 可以使整个场景在光照传播过程中保持能量守恒。全局光照计算需要耗费大量的时间和内存开销, 虽然目前很多方法可以加速绘制<sup>[2-4]</sup>, 但其依然是高度真实感绘制领域的瓶颈。而利用机器学习架构, 可以将部分光照计算映射为学习特定光照训练集数据上, 通过将各个绘制相关的属性映射为像素值, 避免了复杂的物理过程的模拟计算, 降低了计算和存储成本。

近些年来, 学习技术的发展激发了大量基于神经网络的真实感渲染方面的相关研究。这些研究分别集中于解决真实感绘制流程中的某个问题, 并取得了很好的效果。例如, 一些研究者提出了轻量级的材质建模方法, 可以替代工业界传统的复杂材质制作流程<sup>[5-9]</sup>; 一些研究者利用数据驱动的机器学习方法, 大幅提升了全局光照的计算速度<sup>[2,3]</sup>。此外, 许多商业渲染器已经集成了基于机器学习的后处理降噪技术。但是目前机器学习方法并非覆盖所有真实感渲染领域, 对于一些特殊效果的渲染, 例如毛发绘制、布料绘制、复杂光源绘制等依然有待于寻找机器学习解决方案。

机器学习与真实感绘制相结合是近几年来出现的新锐思想, 是目前国内外在真实感渲染方面的热点。最近 Tewari 等人<sup>[10]</sup>对利用深度学习技术进行绘制的方法进行了较为详细的阐述, 但其涉及的相关研究更偏向于计算机视觉, 而非基于物理的真实感绘制。本文希望通过详细总结和分析近些年来基于机器学习的真实感绘制方法、存在的问题以及未来机器学习与真实感绘制相结合应用的趋势, 为研究者提供相关思路。

如何得到遵循物理的光照效果是真实感渲染领域研究的核心目标。决定绘制真实感的因素众多, 按照渲染流程, 主要包括了具有真实感的材质模型、符合物理规律的光线传递模型、后处理去噪等, 按照这个思路, 本文按照图 1 所示框架进行组织。

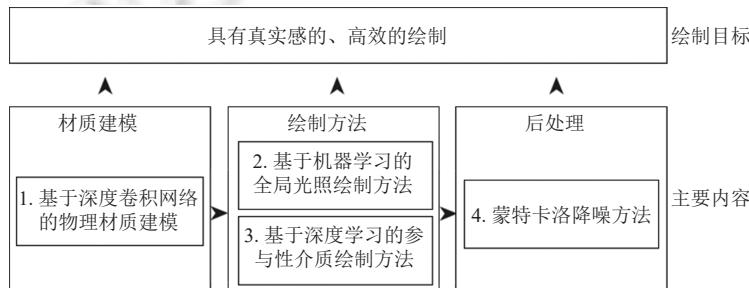


图 1 本文包含的主要内容以及相互关系

本文将围绕 4 个方面展开: 基于深度学习的物理材质建模方法, 基于机器学习的全局光照优化计算方法, 基于深度学习的参与性介质优化绘制方法, 基于机器学习的蒙特卡洛降噪方法。在每个方面本文首先总结国内外相关方法, 并在绘制质量、绘制时间、网络能力等多个方面开展了对比分析。本文最后提出将机器学习和真实感绘制结合的可能思路和未来展望。

## 1 基于深度卷积网络的物理材质建模和绘制

由于物体微观表面上不是绝对光滑的, 这就导致了光线在表面上每个点可以反射或折射至多个不同方向。这种表面微观结构的存在, 使来自不同入射方向的光束在表面的各个出射方向上, 具有一个特定的双向反射分布函数 (bi-directional reflectance distribution function, BRDF)。不同材质表面具有不同的 BRDF 属性, 这些材质属性需要作为参数传递给着色器来进行着色计算。不同的参数组合构成不同的材质模型。通常这些参数包括漫反射 (diffuse)、反射 (specular)、粗糙度 (roughness)、法向 (normal) 等。

传统的材质建模工作通过从各个角度、光照条件下拍摄、测量真实世界的材质以获得其近似的反射属性<sup>[11]</sup>,

使用有监督的深度学习方法大大简化了这个过程。Dror 等人<sup>[12]</sup>首次成功将机器学习应用在材质分类上，继而深度学习成为相关研究中的有利工具。大多数基于学习的材质建模方法的重心在于从现实世界拍摄的材质图片中重建出 SVBRDF (spatially varying bi-directional reflectance distribution function) 模型。经过训练的卷积神经网络 (CNN) 可以从一张拍摄的材质图片还原出对应的 SVBRDF 材质贴图，包括漫反射贴图、反射贴图、粗糙度贴图和法向贴图。

### 1.1 基于拍摄图像的 SVBRDF 重建方法

从单张照片估计表面反射率是一个综合而复杂的问题。目前的研究通过限定一些条件来简化该问题，比如限定光照条件、物体形状等。数据集和网络结构的设计对还原出高质量的材质模型也起到重要作用。

许多深度学习方法的一个共同缺点是它们依赖大型训练数据集，要得到如此庞大的数据集费时费力。Tong 等人<sup>[5]</sup>提出了自增强训练 (self-augmented training) 方法。该研究解决了深度学习过程中训练集数量多且获取困难的问题，利用少量标定数据和大量未标定数据一起训练神经网络，用来从单张照片中预测 SVBRDF 材质参数。图 2 展示了自增强训练方法的过程。用已经具有预测能力的模型预测未标记图片对应的参数，再用这些参数渲染新的图片，那么新渲染出来的图片与预测参数就是配对好的，可以作为训练集继续训练模型。

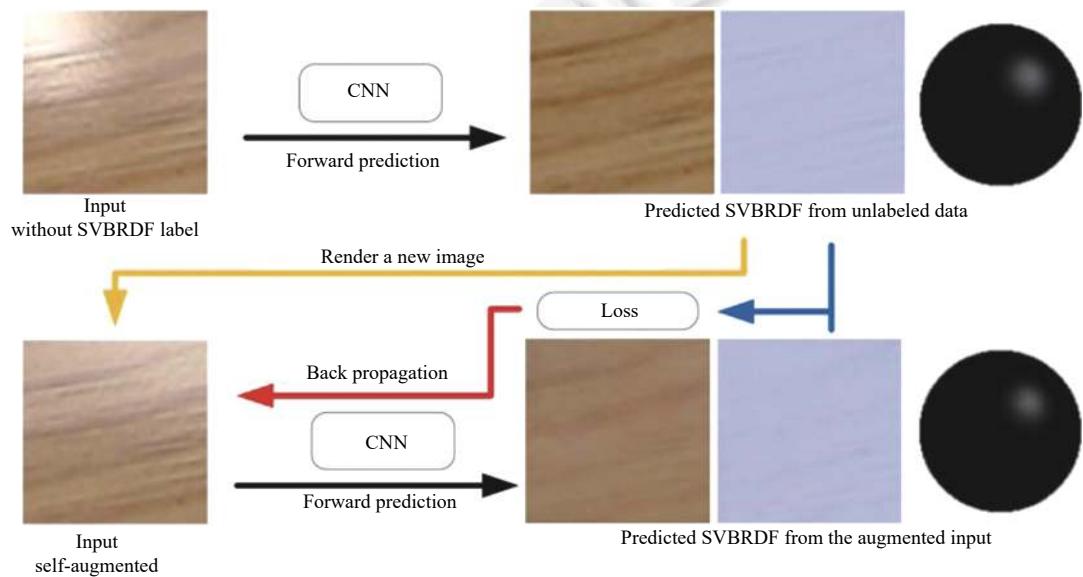


图 2 自增强方法的过程示意<sup>[5]</sup>

在神经网络的设计方面，卷积在提取特征的同时也丢失了全局信息，而材质的全局表观通常为 SVBRDF 重建提供更全面的信息。Deschaintre 等人<sup>[6]</sup>在每层卷积之后又加入了全局特征。研究者们在 U-Net 框架的基础上，补充了一种平行全局特征的神经网络。训练结果与 U-Net 模型的训练结果相比质量更高。

Gao 等人<sup>[13]</sup>提出用多张同视角、不同光源的拍摄图片来进行更精确的材质模型重建。与之前工作不同的是，他们除了直接用损失函数比较最终 SVBRDF 贴图的差异，还用编码器 (encoder) 把 SVBRDF 压缩到高维隐空间，并对这个高维隐空间向量用平滑限制进行优化。最终得到的结果准确度依赖于输入图片的数量，数量越多准确度越高。Guo 等人<sup>[14]</sup>设计了 MaterialGAN 来从渲染图片或者拍摄图片中重建 SVBRDF maps。MaterialGAN 的网络参考了 StyleGAN2<sup>[15]</sup>，在重建过程中能够为材质的逆向渲染提供丰富合理的先验知识。

上述方法都是像素级对应的材质重建，网络的损失函数衡量的是像素之间的差距。Aittala 等人<sup>[16]</sup>依靠基于 CNN 的合成纹理重建来建模材质。他们利用 VGG-19 模型从输入的纹理材质的拍摄图片中提取高维特征来指导建模。该研究不同于前面的几项工作，它的损失函数比较的是提取的高维特征，而非完全一致对应的材质参数。该

方法对于每一个特定的纹理图片都需要进行一次建模。图3展示了基于纹理结构复原的材质建模的重建结果(图3(a))与真实拍摄图片(图3(b))的对比。可以看到,成功复原的材质模型的渲染图片与真实图片并不是每一像素对应一致的。

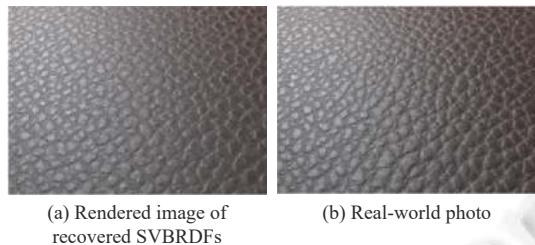


图3 基于纹理重建的材质建模<sup>[16]</sup>

上述方法由于网络参数固定、或者受限于显存,只能生成低分辨率的SVBRDF。Zhao等人<sup>[17]</sup>基于Aittala等人<sup>[16]</sup>的一些假设,对单张拍摄材质图片同时进行SVBRDF重建和合成,解决了从单张拍摄图片生成高分辨率SVBRDF的问题。该方法把SVBRDF的4个组成部分分成两组(roughness map、normal map一组, diffuse map、specular map一组),用两个decoder生成。这样可以避免网络对diffuse map过拟合从而生成更准确的结果。训练好的网络运行一次可以生成相较于输入图片两倍大的SVBRDF,将得到的SVBRDF渲染成图片再输入到网络,就可以得到4倍大的SVBRDF,不断重复这个过程就可以生成高分辨率的SVBRDF。但是该方法同样受限于显存,另外,每张拍摄图片都需要单独训练一个网络。

同样是生成高分辨率SVBRDF,Deschaintre等人<sup>[18]</sup>提出了一种材质外观迁移的方法,将一个或几个低分辨率示例SVBRDF转移到代表相似材料的高分辨率目标图像上去。该方法利用提供的示例微调了一个深层的外观捕获网络<sup>[6]</sup>,以使网络学会从目标图像中提取同示例相似的SVBRDF。研究者们将该方法应用于一种新颖的材质捕获和设计工作流程。具体来说,用户只需要对一个表面拍摄一张高分辨率照片,及一些细节特写照片。从特写照片中提取低分辨率SVBRDF,用这些SVBRDF及渲染图作为小型训练集对现有网络<sup>[6]</sup>进行微调。微调后的网络对目标材质具有更好的拟合能力。最后将高分辨率照片裁切成低分辨率小块,单独重建每一小块的SVBRDF,再将他们拼接起来,这样就能捕获大幅面的材质(如壁画、地板和家具)。但是该方法将高分辨率拍摄图片限制在光照均匀的拍摄条件下,因此不能很好的处理高反射材质。

## 1.2 BRDF 材质编辑方法

另一类方法侧重于在场景中直接编辑BRDF模型。Zsolnai-Fehér等人<sup>[19]</sup>用大量的图片样本训练出不同类型的材质,并用能够实时预测渲染图像的神经网络替换了渲染器的渲染过程。该工作由3个主要模块组成,使用高斯过程回归(Gaussian process regression, GRP)进行材质学习,使用卷积神经网络对材质球图像进行实时预测,使用高斯过程潜在变量模型(Gaussian process latent variable model)把着色器参数编码到一个二维潜在空间,以便材质的微调。但是这些着色器参数与材质外观之间的关系仍让没有相关专业知识的人难以理解。

Zsolnai-Fehér等人<sup>[20]</sup>继续改进了上述工作,使得用户可以更直观地材质而无需理解参数所表示的意义。用户在一张给定的材质球图片上进行编辑(调整颜色、添加高光等),该方法可以给出与用户编辑效果相同的材质模型。该方法首先把用户编辑图片输入一个自编码器,得到潜在空间的参数作为初始参数,随后用优化器优化这个初始参数使得这组参数得到的材质外观更加接近用户要求。改进后的方法可以对用户的编辑更快速的产生更准确的材质模型。Granskog等人<sup>[21]</sup>提出了一种自适应解耦场景的技术。该方法将场景分解出照明、材质和几何信息,并通过混合现有场景的组件来创建新场景。但是该方法的泛化能力稍差,对于真实拍摄的场景效果并不理想。

## 1.3 测量材质的压缩与编辑方法

渲染具有高度真实感的复杂材质的另一种数据驱动的材质模型是测量材质模型,该模型由高精度光学仪器在

不同的视线和入射光线条件下,捕获成千上万个材质样本的图像或者光学数据而得,常见的测量材质模型表示形式有双向纹理函数 bidirectional texture function、测量 BRDF、测量 SVBRDF 等。解析材质模型就是基于这些真实测量的材质数据得来的便于计算的简化材质模型。测量材质模型相较于前文的 SVBRDF 模型能够表现更为复杂的材质外观(如次表面散射,自阴影和自遮挡等)。经典的测量材质有 MERL 材质库,UBO2003 等。测量材质模型的主要缺点是需要大量存储空间用于存储和处理,这使得测量数据的压缩成为实际应用中的关键。传统的压缩方案基于矩阵分解技术,但是压缩后的数据仍是离散的,渲染时依靠在最邻近的样本之间进行插值,容易导致渲染结果有伪影。

Rainer 等人<sup>[22]</sup>提出了一种基于神经网络的 BTF 表示形式(Neural BTF),将原来庞大的数据用网络参数(潜向量与解码器)表示(如图 4)。网络将材质表面每个位置的 BTF(Apparent BRDF, ABRDF)经过几层卷积和池化压缩成 8 位编码,该编码和入射角、出射角一同送入解码器,几个全连接层将压缩后的编码再次解码成目标 RGB 值。该方法能够实现高效压缩与平滑插值,但是对每一种材质都要单独训练一个网络,网络训练代价较高。Rainer 等人<sup>[23]</sup>继续改进上述方法,使得不同材质可以用一个网络压缩表达。相较于之前的网络,Rainer 等人<sup>[23]</sup>加了一个多层次感知机(MLP)。MLP 以一对入射角和出射角为输入,输出一个固定维度的矩阵,解决了不同材质的测量数据维度不一致的问题。

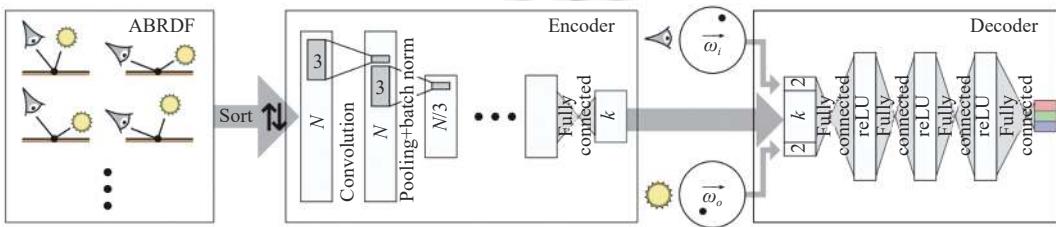


图 4 基于神经网络的 BTF<sup>[22]</sup>

测量 BRDF 数据量与 BTF 一样存在压缩与插值的问题。Hu 等人<sup>[24]</sup>提出了一种基于深度学习的表示形式(DeepBRDF),可以显著降低测量 BRDF 的维度,同时也能够达到较高的恢复质量。该方法将每个测得的 BRDF 视为一系列图像切片,并设计了自动编码器以将高维测量 BRDF 数据非线性压缩到低维潜在空间。研究者们将 DeepBRDF 应用于 BRDF 编辑和 BRDF 重建。对于 BRDF 编辑,可以通过在 DeepBRDF 所在的低维空间上采样得到新的 BRDF,且能够确保 BRDF 数据间的平滑过渡和物理合理性。对于 BRDF 重建,研究者们设计了另一个深度神经网络,将输入图片映射到 DeepBRDF 所在潜在空间,从而可以从单个输入图像自动生成 BRDF 数据。

#### 1.4 SVBRDF 材质绘制方法

尽管 SVBRDF 材质模型得到了广泛使用,但实际镜面高光的高频结构需要考虑离散的、有限的微观几何形状。Kuznetsov 等人<sup>[25]</sup>通过训练生成对抗网络(generative adversarial network, GAN)从合成或测量的数据集中学习高频方向分布(如图 5)。研究者们还使用 cGAN (conditional GAN) 来控制大规模空间纹理。他们将某一特定的空间纹理通过编码器编码成一个固定高维向量,作为 cGAN 的条件,从而生成没有明显重复的大规模空间纹理。在实际绘制时,每次只需查询一个位置和方向的反射率,而运行整个网络、计算全部参数造成了大量的时间和空间的浪费。研究者们通过计算网络的感受野来对网络进行部分评估,从而达到了 SVBRDF 的高效查询和绘制。

#### 1.5 基于拍摄图像的次表面散射材质的重建方法

Che 等人<sup>[26]</sup>首次将深度学习技术用于解决均匀散射逆向求解问题,由一张半透明物体的图像(形状和光照未知)推测次表面散射的光学参数。Che 等人<sup>[26]</sup>设计了一种新的架构,即逆向传输网络(inverse transport network, ITN),将传统的编码器与可微分的蒙特卡洛渲染器连接起来(如图 6)。该渲染器能够针对散射材质图像估算材质参数。使用可微分的蒙特卡洛渲染器的好处在于可以将编码器预测的参数渲染成图像,并与真实图像做比较。Che 等人<sup>[26]</sup>还使用了材料参数化,减少由于散射参数空间中参数间的相似关系而引起的估计误差。在损失函数的设计

上, 该方法使用逐像素权重图来强调图像中有关底层散射参数的信息, 调节训练损失. Che 等人<sup>[26]</sup>的方法是对逆向求解表面散射问题的首次尝试, 现阶段只能解决均匀散射的材质参数求解, 更多改进方法仍待研究.

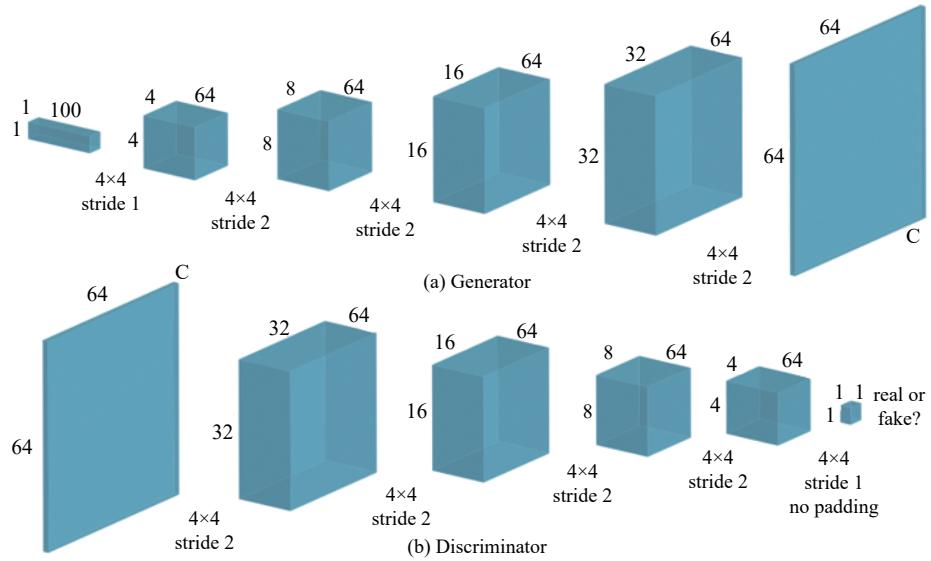


图 5 Kuznetsov 等人<sup>[25]</sup>的 GAN 网络结构

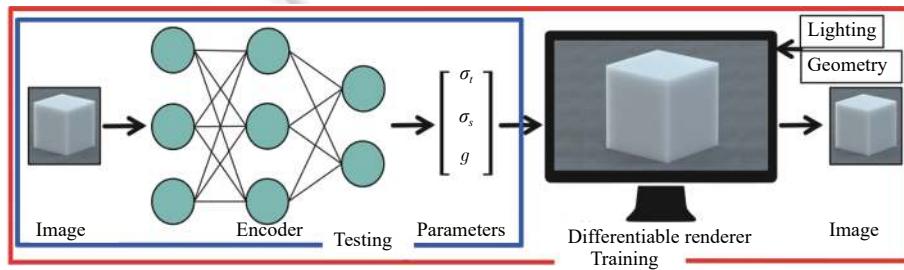


图 6 Che 等人<sup>[26]</sup>的逆向传输网络

## 1.6 对比分析和小结

表 1 中展示了上述基于深度卷积网络的材质建模方法, 并分别从重建准确度、网络训练时间、网络能力、支持材质类型、数据集获取难度五个方面对方法进行了分析. SVBRDF 类型材质的重建准确度的衡量使用了公开的数据集<sup>[6]</sup>, 网络训练时间的衡量统一使用 Nvidia Titan RTX 24 GB 显卡. 其余 BRDF 和 BTF 材质的重建准确度和训练时间的对比分析参考了上述论文中汇报的数据. 表 1 中的重建准确度指的重建材质贴图与目标材质贴图之间的差异, 点数越高表示重建准确度越高. 网络训练时间指的是这些研究用各自的训练集和训练方法所用的时间, 点数越高表示训练时间越短. 支持材质类型指网络能否预测多种材质、预测结果是否是空间各异. 数据集获取难度指训练网络所用的数据集规模大小、采集或生成时间长短、采集或生成过程难易, 点数越高表示数据集获取难度越大.

利用机器学习重建材质模型目前也存在很大局限, 上述的数据驱动的研究工作都需要大量不同材质的数据, 并且材质建模的结果都局限于 CNN 已经学习过的材质类型, 复杂材质如 BSSRDF (bi-directional surface scattering reflectance distribution function) 也难以表现. 另外由于训练集庞大, 计算、学习时间过长, 材质贴图都局限在有限像素的大小, 精度也受到限制.

表 1 材质建模方法对比分析

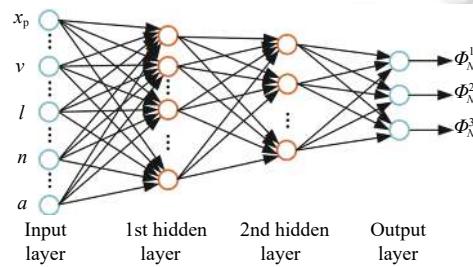
方法	文献	重建条件	重建准确度	网络训练时间	支持材质类型	数据集获取难度
机器学习	[5]	大规模训练集	●●○○○	●●○○○	多种、SVBRDF	●●●●○
	[6]	大规模训练集	●●●○○	●●●○○	多种、SVBRDF	●●●○○
	[13]	单张/多张图片	●●●●○	●●●●○	一种、SVBRDF	●●●○○
	[14]	大规模训练集	●●●●○	●●●●○	多种、SVBRDF	●●●○○
	[16]	单张图片	●●●●○	●●●●●	一种、SVBRDF	●●○○○
	[17]	单张图片	●●●●○	●●●●●	一种、SVBRDF	●●○○○
	[18]	小规模训练集	●●●●○	●●●●○	一种、SVBRDF	●●○○○
	[19]	大规模训练集	●●●○○	●●●●○	多种、BRDF	●●●○○
	[20]	大规模训练集	●●●●○	●●●●○	多种、BRDF	●●●○○
	[21]	大规模训练集	●●●○○	●●●●○	多种、BRDF	●●●○○
非机器学习	[22]	大规模训练集	●●●●○	●●●●●	一种、BTF	●●●●●
	[23]	大规模训练集	●●●●○	●●●○○	多种、BTF	●●●●●
	[24]	大规模训练集	●●●●○	●●●●●	多种、BRDF	●●●●●
	[25]	大规模训练集	●●●●○	●●●●○	多种、NDF	●●●●○
	[26]	大规模训练集	●●●●○	●●●●○	多种、BSSRDF	●●●●○
非机器学习	[11]	大量采集图片, 专业采集设备	●●●●●	—	布料、SVBRDF	—

## 2 基于机器学习的全局光照计算优化方法

全局光照算法同时考虑了直接来自光源的光线(直接光照)和经过其他表面反射的光线(间接光照). 使用全局光照算法可以模拟现实生活中的大部分光照效果, 如阴影、环境遮挡、反射、焦散、次表面散射等. 然而全局光照计算十分费时, 如何使用机器学习方法加速计算全局光照是一个热门议题.

### 2.1 基于预算算辐照度的间接光照计算方法

在加速计算全局光照时, 一种常见的做法是预算算出场景的全局光照信息(如辐射度), 并将其存储于三维空间几何上, 这些预存储的信息会在视线改变的时候被再次利用, 从而避免多遍昂贵的光照计算. Ren 等人<sup>[2]</sup>提出一种辐射度回归函数(RRF), 并使用机器学习方法将其建模为一个多层次神经网络, 用以快速、实时地计算全局光照效果. 该函数可以根据表面上每一点的视点方向与光照条件, 计算出该点的间接光照信息. 图 7 展示了 RRF 模型示意图, RRF 把一组向量(包括表面点位置  $x_p$ , 视线方向  $v$ , 点光源位置  $l$ , 表面法向  $n$ , 反射参数  $a$ ) 映射到间接光出射辐射亮度.

图 7 RRF 的模型示意图<sup>[2]</sup>

RRF 使用了非线性回归模型, 对一个特定场景进行学习. 场景中表面点的位置、光源的位置以及视线方向决定了给定场景的每个表面点的间接光照信息. 训练样本是随机的视线方向、光照条件通过离线渲染预先计算得到的. 在使用 RRF 进行实时绘制时, 首先进行直接光照的计算, 并在计算直接光照的同时, 获取每个表面点的属性;

然后由基于神经网络的 RRF 模型计算得到每个表面点的间接光照信息, 并与计算的直接光照信息进行合成, 得到最终的全局光照结果。该方法可以实时渲染出带有全局光照效果的  $512 \times 512$  分辨率的结果图片, 并保持每秒渲染 30 帧以上的速度, 可有效渲染出包括焦散、高频的反射、间接硬阴影等复杂的光照效果。但是该方法只适用于静态几何场景, 允许光源和视点变化。

Qin 等人<sup>[3]</sup>改进了 RRF 算法, 提出了新的支持透明物体计算的辐射度回归算法 (TsRRF), 可以实现对带有移动的透明物体的场景进行实时的全局光照计算。TsRRF 与 RRF 的第一处不同在于输入样本的选择上。其实, 被 RRF 选作输入样本的属性都可以很好的计算一些光照现象, 例如焦散、反射、硬阴影等。但是当渲染透明物体时, 相交点的属性则不能用于计算这个物体真正的颜色。同样的, 当场景中的物体移动时, 因为 RRF 没有把物体移动纳入考量, 神经网络并不能产生好的结果。在设计 TsRRF 时, RRF 的整体结构并没有被改变, TsRRF 仅仅是提高了输入样本的有效性。如图 8 所示, TsRRF 在输入向量中添加了新的属性 (物体包围盒中心位置 center), 增强了输入数据和结果之间的映射。第二处不同在于, RRF 方法为了降低场景复杂度, 将整个场景分割为几个小部分, 这样还可以达到提升训练样本的有效性的目的。TsRRF 继承了这种思想, 并在分割方法上做了些许的改进, 场景如何分割由对象本身决定。简而言之, 他们给每个对象分配了不同的 RRF, 使得训练样本更有效。

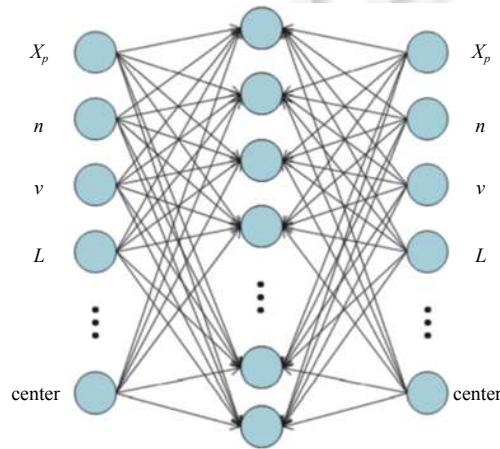


图 8 TsRRF 网络中的一层<sup>[3]</sup>

总体而言, TsRRF 相较于 RRF 做出了以下几点改进: 首先, 选择了与 RRF 不同的光线相交点, 使得 RRF 可以渲染透明物体。其次, 修改了 RRF 使用的输入向量, 增强了输入和输出之间的映射。从结果上来看, 改进后的 TsRRF 方法支持透明物体的渲染, 支持运动物体的渲染, 可以实现实时的渲染全局光照效果。

Currius 等人<sup>[27]</sup>利用一种具有自由方向和任意振幅的球面高斯近似的方法来表示场景中表面上任意一点的预计算光照, 该方法能够高质量的表示预计算的全局光照, 并用于实时渲染场景。该方法训练了一个神经网络为每个球形高斯参数预测合适的值。神经网络可以在相邻的局部光场之间平滑插值, 从而保证照明计算的连贯性。应用于实时渲染时该方法也存在一定的局限, 需要结合后处理降噪, 并且对复杂场景的渲染帧率并不高。Xin 等人<sup>[28]</sup>提出了一种实时渲染的全局光照优化计算方法, 该方法能够生成合理的单次反射的全局照明。该方法首先计算直接光照, 然后使用轻量的神经网络来预测屏幕空间的间接光照。神经网络使用了双边卷积层, 只需要非常少的基本信息(如直接照明, 表面法线和 3D 位置)作为输入。该方法可产生动态场景的单次反射间接照明, 具有更高的渲染质量和更好的时间连续性。

## 2.2 基于机器学习的路径指导方法

使用机器学习或统计学习方法优化光路传输也是实现快速计算全局光照效果的途径之一。传统路径跟踪或者双向路径跟踪方法, 在进行 BSDF 或者光源采样时, 通常只考虑到局部的信息, 而没有考虑到全局的信息, 因此导致在复杂光路时, 得到一些对整体贡献较少的路径, 从而使得绘制噪声较大。路径指导则是通过一定的方式来获取

光路中的更多全局信息,并且根据这些信息来指导重要性采样,从而达到减少噪声的目的。近几年,研究者开始关注基于机器学习的路径指导(path guiding)方法,该方法对于全局光照加速计算效果显著。

Vorba 等人<sup>[29]</sup>通过机器学习的方法,训练出场景中一些采样点的入射辐射亮度角度域分布,分布采用高斯混合模型(GMM)表示。在训练阶段,通过光子映射的方法不断迭代来构建辐射亮度分布。在渲染阶段,用存储的高斯混合模型表示的分布和 BSDF 的分布来进行多重重要性采样,指导新路径的产生。[图 9](#) 是 GMM 拟合方法的说明。第一行是反射率的真实分布,第二行是用高斯混合模型模拟的反射率分布。

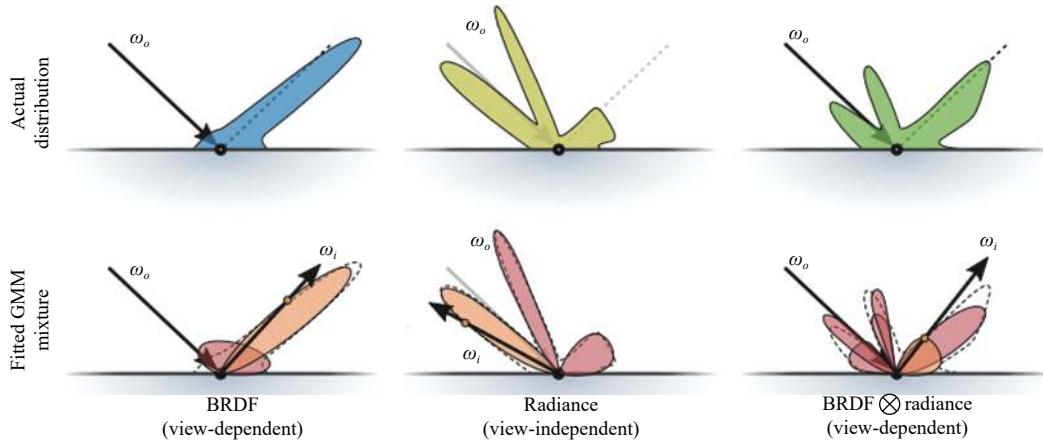


图 9 GMM 拟合方法的说明<sup>[29]</sup>

Herholz 等人<sup>[30]</sup>在此基础上,将训练得到的入射辐射亮度分布与用高斯混合模型表示后的 BSDF 相乘后,得到出射辐射亮度,再进行采样。这种采样出射辐射亮度分布的方式比对两种分布进行重要性采样的方式,采样质量更高,可以得到更优的结果。该方法的缺点在于相乘的额外计算,导致采样效率较低。

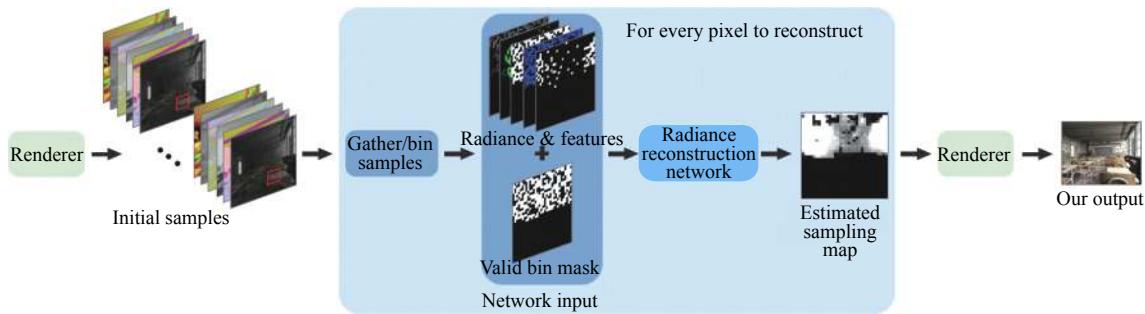
Müller 等人<sup>[31]</sup>提出了一种基于深度神经网络的蒙特卡洛积分采样方法。深度神经网络通过最小化 KL Divergence 或者方差,来学习采样概率分布强度。该方法对局部化的路径引导有很好的效果,并且对于高频空间变化也很适用。对于视角变化、轻微的场景变化,重用某一视角和场景配置的学习结果依然合适。虽然该方法采样的质量很好,但是训练时间成本过高。

Zheng 等人<sup>[32]</sup>也使用了深度神经网络的方法,通过学习得到主采样空间均匀分布的随机数向量,映射成为一个能够反映目标概率的随机数向量,然后用映射后的随机数向量来产生路径。该方法最大的好处在于,蒙特卡洛渲染的过程像黑盒一样,没有受到算法影响。但是,和其他的主采样空间方法相同,该方法不适应于长路径。

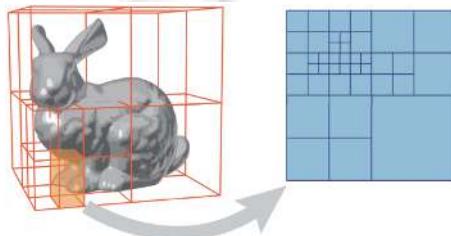
上述这些用于路径指导的重要采样技术的方法是基于在线学习(online training)从而得到采样分布,并且仅在采样数高时收益较大。此外,这些方法在应用到新场景时需要从头开始学习每个新场景的分布,因此它们需要大量的采样和学习时间才能指导后续的采样。Bako 等人<sup>[33]</sup>提出了一种用于路径空间中重要性采样的离线深度学习框架,即使在采样数较少的情况下也可以得到很好的效果。

该方法首先在渲染器的每个像素处保存一个初始采样缓冲区,其中包含第一次光线反弹入射辐射度(包括直接和间接光源),以及一些有用的辅助特征(法向、深度等)。接下来,对于每个像素收集其相邻的辐射度及特征,并根据其方向将每个样本分类到相应的像素均匀网格中。网格的横纵坐标对应球坐标系的方位角和极角,用于参数化入射辐射度。网格附带一个遮罩通道来标识表示该网格处是否收集到采样信息(0 表示该网格处没有任何采样信息)。该方法输入稀疏均匀的网格最终重建入射辐射度的密集分布,然后可以对其进行归一化形成采样图以指导后续采样。[图 10](#) 表示了该方法的路径重建过程。

但是, Bako 等人<sup>[33]</sup>的方法有另外一些局限性。该方法最适合于具有直接照明和一次间接照明的场景。此外,由于在进行重要性采样时该方法没有考虑 BRDF,因此该方法对于漫反射场景效果更好。

图 10 Bako 等人<sup>[33]</sup>的路径指导重建方法

Müller 等人<sup>[34]</sup>提出了一种在路径追踪算法中用于光路构建的无偏方法。该方法利用强化学习渐进地学习场景中空间方向辐射场的近似表示。研究者们设计了一种自适应的时间、空间混合的数据结构，称为 SD 树 (spatio-directional tree, SD-Tree)，用于存储和采样入射辐射度。SD 树由两部分组成，用于在空间上划分 3D 场景的二叉树，和用于模拟球面辐射场的四叉树，每一个二叉树的节点都包含一个四叉树 (如图 11)。SD 树的设计可以很好地适应低频和高频光照，且不需消耗过多内存。虽然其他一些更复杂的算法可能在绘制质量等方面优于该方法，但该方法训练的收敛速度快，且 SD 树可以移植到双向路径追踪、渐进式光子映射等其他方法中使用。

图 11 空间二叉树(左)和方向四叉树(右)<sup>[34]</sup>

Deng 等人<sup>[35]</sup>针对半透明材质渲染的光路追踪提出了一套有效的解决方案。渲染半透明需要模拟大量材质内部的光路，对于具有较大反照率或较小平均自由程的材质，光路的计算成本非常高。Deng 等人<sup>[35]</sup>提出，可以用路径指导的方法来指导采样从而加速收敛。该方法改进了 Müller 等人<sup>[34]</sup>提出的 SD-Tree 结构，能够自适应地学习辐射度的分布，并在参与介质中使用该分布来采样散射方向。该方法大大提高了光路在参与介质中的传输模拟。

### 2.3 基于深度卷积网络的梯度域方法

基于梯度方法的核心思想是利用表面的泊松重构来对初始像素结果 (低采样，含噪点) 和对应的梯度结果进行重构，以获得无噪结果。传统基于梯度的方法泊松重构的质量比较欠缺，近年来，采用机器学习进行泊松重构的方法开始出现，对于重构质量的提升具有重要意义。

Kettunen 等人<sup>[36]</sup>将神经网络与梯度域相结合，设计出优于泊松重构的方法。该方法用卷积神经网络代替了以前的梯度域技术的泊松重构方法，并以符合人类视觉系统的感知图像距离度量来设计网络的损失函数。该方法使用低采样率渲染的图片，以及  $x$ 、 $y$  方向的梯度图和一些辅助特征 (反射率，法向，深度) 作为网络输入。网络结构的设计融合了 U-Net 结构和 DenseNet (如图 12)，不同分辨率之间的网络层之间的结构类似于 U-Net。网络从高分辨率向低分辨率压缩，随后从低分辨率向高分辨率还原，分辨率相同的层之间使用跳跃连接 (skip connection)。相同分辨率的网络层之间的结构类似于 DenseNet，每一个处理块 (processing unit) 都接收前面所有相同分辨率的处理块结果作为输入。该方法改善了梯度域路径跟踪方法获得的图片质量。

Guo 等人<sup>[37]</sup>提出了首个增强蒙特卡洛方法渲染图片质量的无监督学习方法。该方法同样使用低采样率渲染的图片，以及  $x$ 、 $y$  方向的梯度图和辅助特征 (反射率，法向，深度) 作为网络输入。网络采用多分枝的结构 (data branch,

gradient branch 和 G branch), 可以同时提取低频内容特征和高频细节特征. 该方法以无监督的方式设计和训练网络, 避免了训练集难获取的难题. 同时为了适应这种无监督的设计, 网络在训练时有效利用了输入的辅助特征, 更多的侧重于梯度图的准确性而不完全依赖图片重建的准确性.

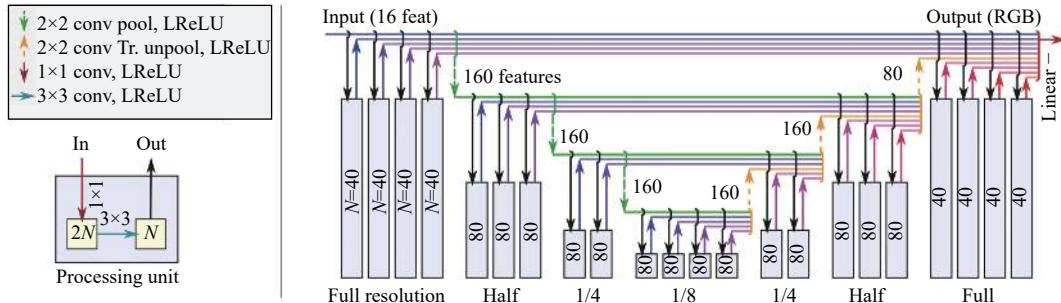


图 12 Kettunen 等人<sup>[36]</sup>的网络结构

## 2.4 光照采样算法优化

Hermosilla 等人<sup>[38]</sup>提出一种利用深度学习直接从三维场景映射到渲染图像的方法, 避免了蒙特卡洛采样. 该方法首先将三维场景表示为非结构化 3D 点云, 然后使用 3D-2D 的网络将其投影到 2D 输出图像. 该方法适用于环境光遮蔽 (AO)、全局光照 (GI)、和次表面散射 (SSS), 但是每种效果都需要训练网络.

Huo 等人<sup>[39]</sup>利用大量数据集, 针对首次反弹入射辐射场的自适应采样和重建训练神经网络. 该方法结合了基于深度强化学习 (DRL) 的质量网络 (quality network, Q-network) 和基于 4D 卷积神经网络的重建网络 (reconstruction network, R-network). Q 网络可预测和指导自适应采样过程, R 网络可重构 4D 空间中的入射辐射场. 如图 13 所示, 该方法首先将图像空间划分为块 (图 13(a)), 并在每个块中随机发射采样光线 (图 13(b)). 使用 Q 网络评估方向空间的构建或采样的质量. 其中图 13(c) 的结果用于指导 R 网络做自适应采样和重构, 最终由 R 网络输出重建的渲染结果 (图 13(d)).

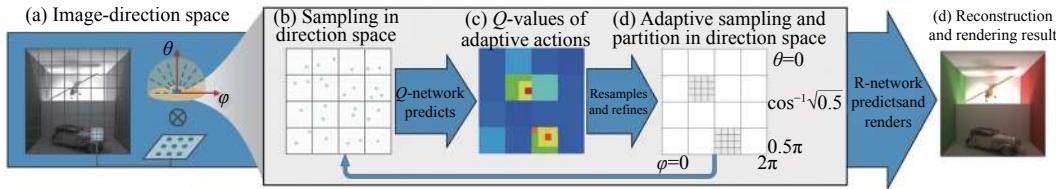


图 13 Huo 等人<sup>[39]</sup>的算法流程

Dahm 等人<sup>[40]</sup>将强化学习方程和光照方程联系起来, 用强化学习的方法逐步逼近贡献高的光路, 解决了光照方程计算时采样效率低的问题. 该方法将 Q-learning 算法<sup>[41]</sup>中的状态  $s$  与光照方程中的位置  $x$  关联起来, 行为  $a$  与从  $x$  处沿  $w$  方向出射一条光线关联起来等等. 该方法的新颖之处在于, 在渲染过程中使用强化学习提高采样重要性, 从而提高路径追踪效率.

## 2.5 对比分析和小结

表 2 中展示了上述基于机器学习的全局光照绘制方法, 归纳了各个方法适用绘制的场景, 并分别从绘制质量、网络训练时间、绘制效率、数据集获取难度 4 个方面, 对相关方法进行了对比分析. 对比分析参考了上述论文中汇报的数据. 表 2 中的绘制质量指的绘制结果与高采样的路径追踪算法得到的结果之间的差距, 点数越高表示质量越高. 网络训练时间指的是用不同规模场景的数据训练所需的平均时间, 点数越高表示训练时间越短. 绘制效率表示绘制一帧所需时间, 点数越高表示所需时间越短. 数据集获取难度指训练网络所用的数据集规模大小、生成时间长短、生成过程难易, 点数越高表示数据集获取难度越大.

表 2 全局光照绘制方法对比分析

方法	文献	适用场景	绘制质量	网络训练时间	绘制效率	数据集获取难度
机器学习	[2]	静态几何场景, 光源变化, 视点变化	●●○○○	●●●●○	●●●●○	●●●●○
	[3]	动态几何场景, 光源变化, 视点变化	●●○○○	●●●●○	●●●●○	●●●●○
	[27]	静态几何场景, 静态光源, 视点变化	●●○○○	●●●●○	●●●●○	●●●●○
	[28]	实时渲染中计算单次漫反射间接光照	●●●●○	●●●○○	●●●●●	●●●●○
	[29]	单一场景, 高采样数	●●●○○	●●●●○	●●●●○	●●●○○
	[30]	单一场景, 高采样数	●●●○○	●●○○○	●●●○○	●●●○○
	[31]	单一场景, 高采样数	●●●●○	●●●○○	●●●○○	●●●○○
	[32]	单一场景, 高采样数	●●●●○	●●●●○	●●●○○	●●●○○
	[33]	任意场景(漫反射), 低采样数	●●●●○	●●●○○	●●●○○	●●●●○
	[34]	单一场景, 任意采样数	●●●●●	●●○○○	●●●●○	●●●○○
	[35]	次表面散射的路径指导	●●●●○	●●●○○	●●●○○	●●●●●
	[36]	任意场景, 梯度域渲染器	●●●○○	●●●○○	●●●○○	●●●●○
	[37]	任意场景, 梯度域渲染器	●●●●○	●●●●○	●●●●○	●●●○○
	[38]	场景直接映射到渲染结果	●●●○○	●●●○○	●●●●●	●●●●●
	[39]	单次漫反射间接光照场景	●●●●○	●●○○○	●●●●○	●●●●○
	[40]	任意场景, 蒙特卡洛采样	●●●○○	●●●○○	●●●○○	●●●○○
非机器学习	[42]	实时渲染中的漫反光间接光照	●●●○○	—	●●●●○	—
	[43]	实时渲染中的间接光照	●●●○○	—	●●●●●	—

传统的全局光照绘制方法使用虚拟点光源 (virtual point lights, VPLs)、预算辐射度 (precomputed radiance transfer, PRT)、球谐函数表示辐射度等方法近似模拟全局光照, 准确度和存储空间都受到影响。基于机器学习的全局光照绘制方法在提高绘制效率的同时也面临很多问题, 例如训练集难以获取、训练时间长、适用场景受到局限等。由于训练使用的场景复杂性不高, 因此这些方法在处理实际问题时效果可能并不理想。

### 3 基于深度学习的参与性介质优化绘制方法

在真实场景中, 随时可见各式各样的参与性介质 (如蜡烛, 牛奶, 橄榄油, 烟雾等), 光线在参与介质中传递时会被吸收或者发生散射。为了模拟介质中的散射现象, 需要花费大量计算时间。特别是由异质密度形成的可见结构 (如大气云) 更加挑战渲染算法的效率。参与性介质的表观通常是由成千上万的内部光子物质相互作用而成, 即使是忽略它的离散性质, 用连续体积近似模拟, 通过求解辐射传递方程来估算光传输 (RTE)<sup>[44]</sup> 仍需大量计算。而基于预算的方法<sup>[45,46]</sup> 将特定的材质的散射信息用表存储起来, 绘制时直接从预存表中提取对应的辐射度值。但是这类方法耗费大量的表存储空间。故目前参与性介质绘制方法在互动性、即时性和吞吐量大的应用需求中尚存在较大瓶颈。一些方法通过简化计算来提升渲染速度, 例如近似值扩散理论<sup>[47,48]</sup>, 密度估计<sup>[49,50]</sup>, 半解析解<sup>[51]</sup> 等方法, 但是这些方法大大降低了视觉质量。

Kallweit 等人<sup>[52]</sup> 提出了一种使用蒙特卡罗积分和神经网络相结合的高效绘制大气云的技术 (radiance-predicting neural networks, RPNN)。该方法从大量样本中提取采样点对应的相关着色位置和光源的几何信息, 再将这些信息输入深度神经网络中, 以得到最后的辐射度。研究者们使用了一个基于点模板 (stencils) 的层次结构 (如图 14 左图), 每一层模板的覆盖范围是上一层的 8 倍。这样输入信息不仅能够表示微小的细节, 同时又能有大气云的整体形状信息。该方法使用一个 10 层的渐进式学习的神经网络 (如图 14 右图), 每一层的输入来自上一层神经网络和新的点模板。该方法在保证渲染质量的同时速度提高了千倍 (如图 15)。

该研究使用蒙特卡罗来计算直接内散射的颜色值, 使用训练好的神经网络得到间接散射, 并添加直接和间接分量以获得绝对的散射度。将预测数值整合到环境发射器的立体角上即可以在环境照明下渲染大气云。

针对目前基于点缓存或者光亮度缓存的参与性介质绘制中缓存数据带来的内存瓶颈问题, Ge 等人<sup>[53]</sup> 提出

用特定的神经网络来拟合散射信息表的方法, 将预计算的多重散射通过神经网络来表示。但是该方法仅适用于单一介质。Ge 等人<sup>[54]</sup>继续改进网络使其支持多种介质的表示。该方法通过具有四层的神经网络结构来学习多重散射函数(如图 16 所示), 输入层包括参与性介质的各向异性值  $g$  和散射反照率  $\alpha$ , 以及采样点的位置  $r(\rho; z)$  和方向  $(\theta; \varphi)$ , 输出层是相关的辐射度。该方法适用于双次散射和多次散射计算, 可有效将存储从 50 GB, 降低到 23.6 KB。通过 GPU 架构将该方法集成到虚拟光线计算方法(virtual ray light, VRL)中, 参与性介质绘制速度提高到每帧 50 ms 以内, 从而达到可交互绘制的目的。

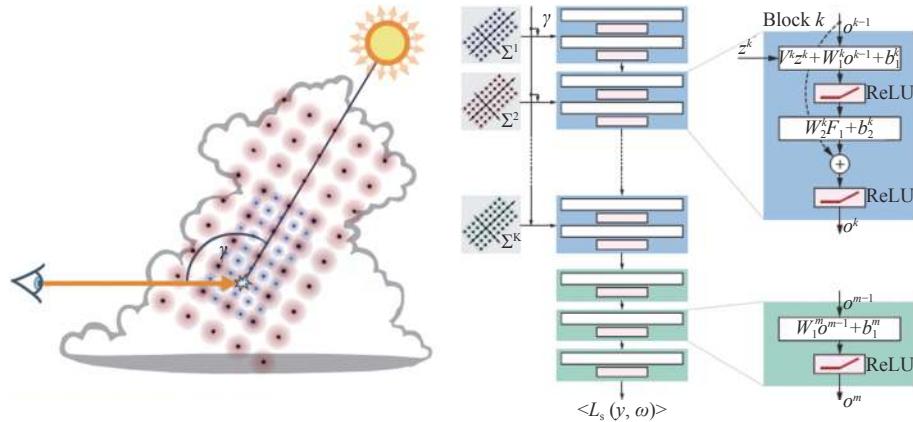


图 14 点模板结构示意(左)及渐进式学习的神经网络结构(右)<sup>[52]</sup>

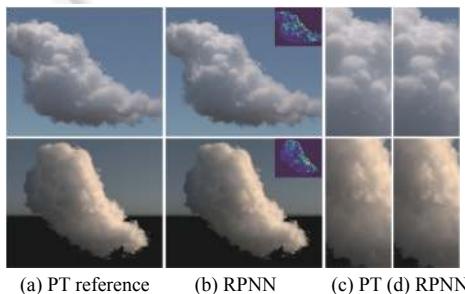


图 15 路径追踪算法(PT)与使用深度学习方法(RPNN)的结果对比<sup>[52]</sup>

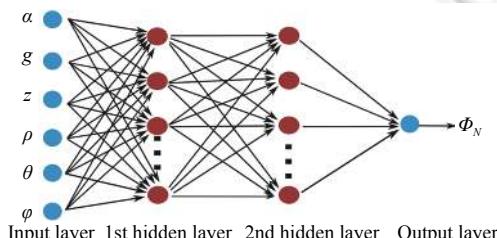


图 16 Ge 等人<sup>[54]</sup>的 4 层神经网络结

Vicini 等人<sup>[55]</sup>引入了支持任意均质介质参数的新型形状自适应 BSSRDF 模型, 在不违背漫反射模型(diffusion models)的典型假设的情况下保持了经典 BSSRDF 模型的效率, 极大地提高了总体准确性。该方法依赖于 3 个神经网络的组合, 这 3 个神经网络共同构成了 BSSRDF 采样曲面的概率生成模型。第 1 个特征网络(feature network)对一些输入参数进行预处理得到大量特征。这些输入参数包括材质特性(反射率, 各向异性和折射率), 入

射方向以及描述入射位置附近几何变化的描述符。为了描述局部几何形状, 该方法使用低阶三元多项式对近似的距离函数进行编码, 使该模型适应于几何细节, 包括曲率, 厚度, 角, 以及圆柱状环形凸出物(例如手柄)。第2个散射网络(scatter network)学习从体积路径跟踪器生成的参考分布中的采样; 第3个吸收网络(absorption network)可以对多重散射材质的分布的散射因子(scale factor)进行回归拟合。图17展示了该网络的3个组成部分。

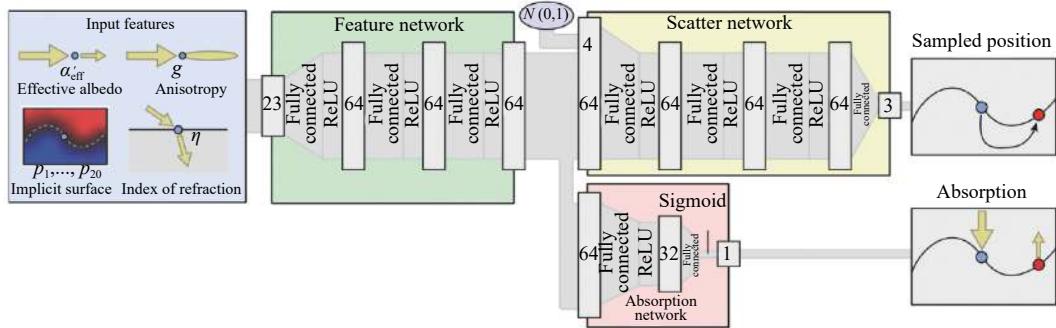


图17 Vicini等人<sup>[55]</sup>的神经网络BSSRDF模型

表3中展示了上述3种基于深度卷积网络的参与性介质优化绘制方法, 归纳了各个方法适用绘制的场景, 并分别从绘制质量、网络训练时间、绘制效率、数据集获取难度4个方面, 对相关方法进行了对比分析。对比分析参考了上述论文中汇报的数据。表3中的绘制质量指的绘制结果与高采样的路径追踪算法得到的结果之间的差距, 点数越高表示质量越高。网络训练时间指的是用不同规模场景的数据训练所需的平均时间, 点数越高表示训练时间越短。绘制效率表示绘制一帧所需时间, 点数越高表示所需时间越短。数据集获取难度指训练网络所用的数据集规模大小、生成时间长短、生成过程难易, 点数越高表示数据集获取难度越大。

表3 参与性介质优化绘制方法对比分析

方法	文献	适用场景	绘制质量	网络训练时间	绘制效率	数据集获取难度
机器学习	[52]	体积云绘制	●●●●●	●●●●○	●●●○○	●●●●○
	[53]	均匀散射材质绘制	●●●●○	●●●○○	●●●●○	●●●○○
	[54]	均匀散射材质绘制	●●●●○	●●●●○	●●●●●	●●●●○
	[55]	均匀散射材质绘制	●●●●○	●●●●○	●●●○○	●●●●○
非机器学习	[56]	均匀/非均匀散射材质绘制	●●●●○	—	●●●○○	—

使用机器学习优化参与性介质绘制的方法现在仍处于初步探索的阶段, 现有方法存在很多局限(如局限于特定场景和均匀散射材质)。另一方面, 参与性介质的绘制需要计算材质内部多次光线弹射, 计算量、存储量都很大, 利用机器学习简化绘制过程也大有前景。

#### 4 基于深度卷积网络的蒙特卡洛降噪

基于蒙特卡罗方法的路径追踪算法被广泛应用于动画、影视特效等产业中<sup>[57]</sup>。该算法虽然能够满足严格的渲染质量要求, 但其计算成本很高, 要得到无噪声的结果所需时间也很长。特别是渲染光路传输很复杂的场景时, 该算法的渲染结果中很容易出现噪声。超采样(supersampling)是离线渲染中生成高质量抗锯齿图像的实际标准技术, 但其高昂的计算成本限制了交互式应用程序的应用。

因此, 研究者提出了很多针对基于蒙特卡罗路径追踪算法的降噪方法。其中, 基于图像空间的降噪算法因其高效性且易于集成到现有渲染管线而受到广泛关注, 这类基于图像的降噪算法已经能够在低采样率下得到高质量的渲染结果<sup>[58]</sup>。

虽然有一系列的基于图像空间的降噪算法不断被提出, 但大多数最先进的技术还都是使用一种回归模型框

架<sup>[59,60]</sup>. 这种回归模型虽在降噪方面有着许多提升, 但这些提升是以不断增加的计算复杂性为代价的, 同时提升的渲染效果也逐渐减少. 这是因为更高阶的回归模型对于输入的有噪声数据更易过拟合.

#### 4.1 基于深度卷积网络的路径追踪降噪

为了解决上述问题, Kalantari 等人<sup>[61]</sup>使用一个多层次感知机神经网络, 通过一组有噪声的输入和相应的无噪声输出训练集, 训练得到一个非线性回归模型, 从而实现对蒙特卡罗路径追踪算法渲染结果的降噪. 在训练阶段, 他们使用较低的采样率渲染出有噪声的输入图片, 使用高采样率渲染得到无噪声的目标图片 (ground-truth), 同时获取并保存渲染有噪声图片时每个像素周围方形区域的各种有用的特征值. 最后使用这些训练数据对提出的多层次感知机神经网络进行训练. 然而这个方法中使用的是一个相对简单的多层次感知机神经网络, 且只使用了较小数量的场景去获取数据集图片. 另外, 该方法将滤波器硬编码为联合双边滤波器或联合非局部均值滤波器, 限制了方法的灵活性.

Bako 等人<sup>[62]</sup>提出了一种新的有监督学习框架及新的深度卷积神经网络 (kernel-predicting convolutional networks, KPCN). 该方法使用大量级的产品级数据 (来自动画电影《Finding Dory》) 训练网络, 满足了深度神经网络对训练数据集的大量级、高多样性的需求. 首先使用网络获取目标像素的最优邻域权重, 再根据邻域噪声像素的颜色值加权平均来确定这一像素的最终颜色值. 该方法使用一种双网络架构——将路径追踪分为 Diffuse 和 Specular 两个部分分别搭建网络, 进行训练、预测, 再组合得到最终结果 (如图 18).

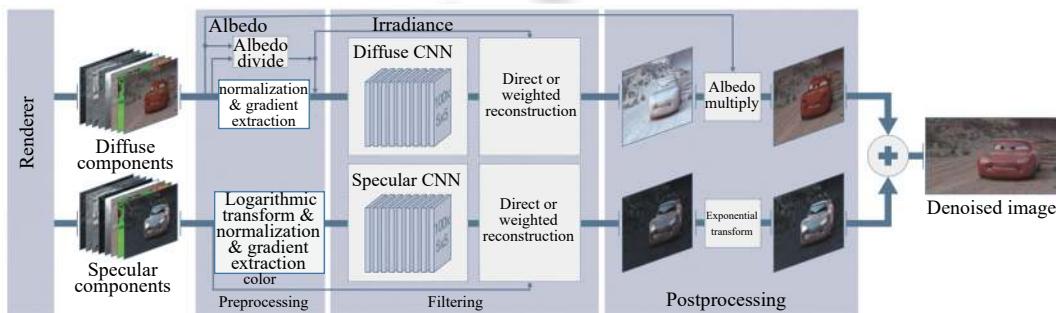


图 18 KPCN 架构概览<sup>[62]</sup>

相比之前方法, 使用 KPCN 可以获得更灵活且复杂的滤波器, 但是该方法并没有考虑保持帧间连贯性的去噪. 图 19 展示了 KPCN 的降噪结果.

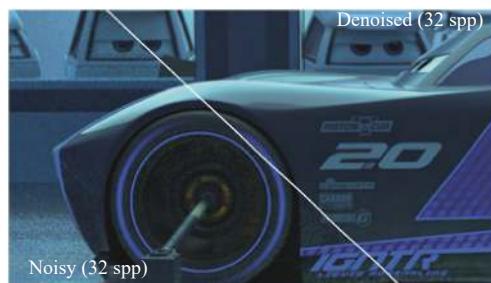


图 19 KPCN 降噪结果<sup>[62]</sup>

Vogels 等人<sup>[63]</sup>则认为, 目前使用机器学习方法训练的降噪器都普遍面临以下问题: 数据获取效率问题, 时序稳定性问题和用户控制问题. 在他们的方法中, 分别对上述问题提出了解决方案. 研究者们扩展了 KPCN 框架, 添加了一组具有特定任务的模块: 一是 source-aware encoder 模块, 用以抽取低阶特征并组合进一个特征空间内, 使得训练后的网络能够迅速适应新的输入数据; 二是 spatial and temporal 模块, 抽取高阶、抽象的特征来进行基于滤波核的重建, 这是在 3 个不同的空间尺度上进行的, 以减少低频的走样; 三是 error-predicting 模块, 用来推断可

用于自适应采样的重建误差图。整个网络使用了一类非对称的损失函数训练，能够保持细节，并在使用时直接控制并权衡方差值和偏差值。

Chaitanya 等人<sup>[64]</sup>提出了具有帧连续性的降噪方法，它可以交互式的对低采样的全局光照序列帧进行降噪处理。Gharbi 等人<sup>[65]</sup>首次提出了一种可以直接从蒙特卡洛样本中学习对低采样渲染图像进行去噪的卷积网络。网络的输入是待降噪的低采样图片以及蒙特卡洛采样过程中计算得到的大量特征向量（镜头光圈半径、相机的视场、镜头对焦距离、样本坐标、漫反射辐照度、镜面反射辐照度、光线与平面相交处材质属性、光线反射方向）。为了保证降噪结果与样本的顺序无关以及支持任意数量的样本，在网络设计上需要单独处理每个样本，同时让样本获得充分的邻域信息。为此，Gharbi 等人<sup>[65]</sup>用全连接网络为单个样本生成样本嵌入  $E$ ，并将其平均化为上下文特征  $C$ ，通过 U-Net 结构的卷积网络传播信息，样本嵌入和上下文功能交替重复 3 次以更好地传播信息（如图 20）。该方法对具有景深和运动模糊的降噪结果得到显著提升。

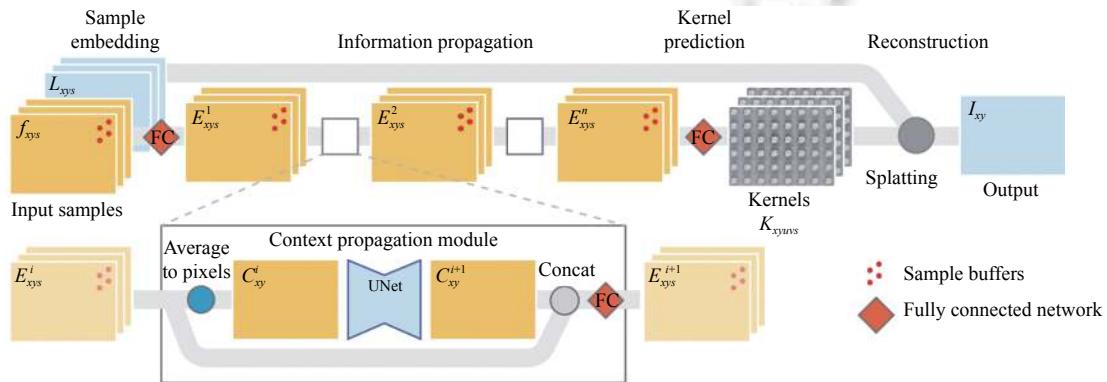


图 20 Gharbi 等人<sup>[65]</sup>的网络设计<sup>[65]</sup>

Xu 等人<sup>[66]</sup>则利用生成式对抗网络，通过学习一组高质量蒙特卡罗路径跟踪图像的分布，帮助去噪网络产生更真实的高频细节和全局光照。他们延伸了 Bako 等人<sup>[62]</sup>的工作，同样将待去噪图片分成 specular、diffuse 两部分分别降噪，利用额外的输入的特征来辅助网络训练。不同之处在于 Xu 等人<sup>[66]</sup>使用了一个自适应模块来帮助网络判断输入的特征是否需要用于降噪处理。

Kuznetsov 等人<sup>[67]</sup>引入了深度自适应采样和重建 (DASR)，以实现低样本数渲染。他们的架构使用两个 CNN：一个网络（采样网络）学习预测样本密度图，另一个网络（降噪网络）学习如何对自适应采样渲染的图像进行降噪。首先以低采样渲染场景作为第一个网络的输入。该网络会输出一个样本密度图，这些新产生的自适应分布的样本会和初始样本一起指导路径采样，再经过第二个网络降噪生成最终渲染图。两个网络共用一个损失函数，一起训练，互为补充：如果在图像某处降噪网络不能很好降噪的话，采样网络会给此处多分配些采样数，反之亦然。

Hasselgren 等人<sup>[68]</sup>扩展了 Kuznetsov 等人<sup>[67]</sup>的网络，可以实时地对连续帧降噪。该方法同样用采样和降噪两个网络，但是融合了循环反馈环和时间重投影。循环反馈环和时间重投影利用去噪后的输出图片作为下一帧的输入，提高了降噪的连续性。在学习样本密度图时仅使用时间重映射影的数据和当前帧的几何缓冲区数据，而不必再低采样产生当前帧的噪声图片。在改进降噪网络时，Hasselgren 等人<sup>[68]</sup>借鉴了 Vogels 等人<sup>[63]</sup>提出的多尺度模块。Hasselgren 等人<sup>[68]</sup>提出的网络比 Chaitanya 等人<sup>[64]</sup>在参数量上减少了近 10 倍，但在序列帧上仍然可以产生更高质量的结果。

Lin 等人<sup>[69]</sup>利用神经网络分别提取特征缓冲与颜色缓冲，并在网络训练过程中增加感知损失，以增强细节效果。该方法将路径空间中的光传输协方差特征作为特征之一，用于保留照明细节。这些设计使得该方法在降噪的同时能更好地保留细节。

## 4.2 基于深度卷积网络的光子映射降噪

随机渐进式光子映射是一种被广泛使用的全局光照算法，作为光子映射的改进算法，它可以有效地计算焦散

等复杂的光照效果。然而,作为一种有偏且一致的算法,随机渐进式光子映射在渲染参数不合适或渲染迭代次数不足时,其渲染结果常常被偏差和方差同时影响,具体表现为物体表面大小各异的光斑及噪声,这有别于其他无偏且一致的算法。Zeng 等人<sup>[70]</sup>提出了第一个基于深度学习的,在图像空间对随机渐进式光子映射这一有偏算法进行降噪的方法。

在对随机渐进式光子映射进行降噪时,拥有更大的视野域的降噪网络可以更有效地处理多尺度的光斑和噪声,特别是位于低频表面的较大的光斑,但这类降噪网络往往不善于处理高频区域的噪声。而一个拥有小视野域的降噪网络则恰好相反。基于以上观察,Zeng 等人<sup>[70]</sup>提出了一种全新的网络结构,它使用了一组特殊的残差格模块。使用这种残差格模块同时集合大视野域和小视野域的优点,可以有效处理随机渐进式光子映射的多尺度噪声。同时,为了进一步提高降噪质量并更好地保持光照细节,该方法首先将渲染结果分为全局和焦散两个成分,再输入两个网络分别进行降噪。此外,该方法还使用一组光子相关的辅助特征向量帮助降噪网络更高效地处理噪声,同时有效保持焦散等光照细节。该方法可以有效处理随机渐进式光子映射中的多尺度噪声,特别是善于处理位于低频区域的较大光斑,同时又可以保留较多光照细节。

### 4.3 对比分析和小结

表 4 中展示了上述基于机器学习的蒙特卡洛降噪方法,并分别从降噪质量、网络训练时间、单帧降噪时间、帧连续性方面对方法进行了分析。对比分析的评分依据这些研究论文中提供的数据。表 4 中的降噪质量指的降噪结果与高采样的路径追踪算法得到的结果之间的差距,点数越高表示质量越高。网络训练时间指的是这些研究用各自的训练集和训练方法所用的时间,点数越高表示训练时间越短。单帧降噪时间指的是对一张  $1280 \times 720$  的图片降噪所用的时间,点数越高所需时间越短。帧连续性表示对序列帧降噪得到的序列是否连续。数据集获取难度指训练网络所用的数据集规模大小、生成时间长短、生成过程难易、所需的输入特征数量多少,点数越高表示数据集获取难度越大。由于大部分研究都使用了相同的开源数据集,因此上述几项研究的数据集获取难易程度很难有区分。对比分析参考了上述论文中汇报的数据。

表 4 降噪方法对比分析

方法	文献	降噪质量	网络训练时间	单帧降噪时间(720p)	帧连续性	数据集获取难度
机器学习	[61]	●●●○○	●●●●●	●●○○○	不连续	●●●●○
	[62]	●●●○○	●●●○○	●●○○○	不连续	●●●●●
	[63]	●●●●○	●●○○○	●●○○○	连续	●●●●○
	[64]	●●●○○	●●●○○	●●●●○	连续	●●●●●
	[65]	●●●●○	●○○○○	●○○○○	不连续	●●●●●
	[66]	●●●●○	●●○○○	●●●●○	不连续	●●●●●
	[67]	●●●●○	●●○○○	●●●●○	不连续	●●●●●
	[68]	●●●●●	●●○○○	●●●●●	连续	●●●●○
	[69]	●●●●○	●●○○○	●●●○○	不连续	●●●●○
	[70]	●●●●○	●●●○○	●●●○○	不连续	●●●●○
非机器学习	[60]	●●●○○	—	●●○○○	不连续	—

基于机器学习的后处理去噪方法相较于人工设计的降噪模型可以得到更高质量的滤波效果,但对于蒙特卡洛渲染来说,渲染数据集中作为预测目标的参照是十分昂贵的。另外对于数据来源的适应性以及连续帧的降噪都是非常值得关注的问题。

## 5 未来展望

目前深度学习在三维场景的高度真实感绘制中已经有了不少的应用,比如在绘制过程中重要性采样、SVBRDF 材质建模、参与性介质散射计算以及后处理中的蒙特卡洛降噪等方面。基于神经网络技术的真实感渲染避免了复杂的物理过程的模拟计算,可以大大降低计算成本或者降低存储成本。但是目前机器学习方法尚不能完全取代传统的光照物理模型计算法,仍然存在一些可以改进的方向。

首先, 如何把渲染的过程用深度学习来模拟是非常挑战的。目前的工作中, 有些将三维场景投影为二维的缓冲区, 然后学习各类缓冲区和最终绘制结果之间的映射关系; 有些则是局限在特定的物体上, 比如云中的散射, 而当变成更加复杂的物体时则会出现一些走样, 这些都意味着选择适合深度学习的三维场景表示方法是具有挑战的。虽然有些文章中采用了八叉树或者体素的方式来表示三维场景, 并且用深度学习进行一些应用, 但是在绘制方面, 并不是直接适用的, 以上两种离散化的表示方式均会导致走样产生。

在基于机器学习的重要性采样方面, 目前机器学习方法可以通过学习场景中光照等的分布情况, 用于绘制过程中的重要性采样, 从而使得采样到更高贡献的路径, 提高收敛效率。由于场景中的光照分布等具有复杂性, 显式的学习和表示比较困难, 而通过机器学习这样的黑盒操作来进行学习和表示具有很大的优势。但是参考目前提出的方法, 存在一个很大问题就是采样效率低的问题, 由于每次采样需要对整个网络进行计算, 使得采样代价较大, 而采样在绘制过程中需要重复成千上万次的操作, 因此采样的效率将大大影响最终的绘制效率。也就是在相同的绘制时间内, 虽然基于机器学习的采样质量更高, 但是得到的效率可能并不比传统方法高。因此如何提出合理的神经网络框架, 提高采样效率是十分必要的。

深度神经网络在蒙特卡洛降噪方面已经表现出很大的优势, 能够得到比以往传统的基于图像空间的方法更好的效果。但是仍然存在一些挑战, 目前基于深度学习的降噪针对的材质具有一定的局限性, 缺少对特殊材质的处理, 比如复杂的微表面材质中的亮片划痕等, 它们与噪声的分布是比较相近的, 如何区分出材质本身还是噪声是一件困难的事情。

总之, 用深度学习来完成整个绘制工作是非常大的挑战, 也是未来需要关注和研究的热点问题。

### References:

- [1] Kajiya JT. The rendering equation. ACM SIGGRAPH Computer Graphics, 1986, 20(4): 143–150. [doi: [10.1145/15886.15902](https://doi.org/10.1145/15886.15902)]
- [2] Ren PR, Wang JP, Gong MM, Lin S, Tong X, Guo BN. Global illumination with radiance regression functions. ACM Trans. on Graphics, 2013, 32(4): 130. [doi: [10.1145/2461912.2462009](https://doi.org/10.1145/2461912.2462009)]
- [3] Qin X, Xiao SJ. Transparent-supported radiance regression function. In: Proc. of the 13th ACM SIGGRAPH Int'l Conf. on Virtual-Reality Continuum and its Applications in Industry. Yekaterinburg: ACM, 2014. 197–200. [doi: [10.1145/2670473.2670498](https://doi.org/10.1145/2670473.2670498)]
- [4] Xu X, Wang L, Xu YN, Yang CL, Meng XX. A survey of point based global illumination. Journal of Computer-aided Design & Computer Graphics, 2019, 31(5): 689–697 (in Chinese with English abstract). [doi: [10.3724/SP.J.1089.2019.17322](https://doi.org/10.3724/SP.J.1089.2019.17322)]
- [5] Li X, Dong Y, Peers P, Tong X. Modeling surface appearance from a single photograph using self-augmented convolutional neural networks. ACM Trans. on Graphics, 2017, 36(4): 45. [doi: [10.1145/3072959.3073641](https://doi.org/10.1145/3072959.3073641)]
- [6] Deschaintre V, Aittala M, Durand F, Drettakis G, Bousseau A. Single-image SVBRDF capture with a rendering-aware deep network. ACM Trans. on Graphics, 2018, 37(4): 128. [doi: [10.1145/3197517.3201378](https://doi.org/10.1145/3197517.3201378)]
- [7] Li ZQ, Sunkavalli K, Chandraker M. Materials for masses: SVBRDF acquisition with a single mobile phone image. In: Proc. of the 15th European Conf. Munich: ECCV, 2018. 74–90. [doi: [10.1007/978-3-030-01219-9\\_5](https://doi.org/10.1007/978-3-030-01219-9_5)]
- [8] Li ZQ, Xu ZX, Ramamoorthi R, Sunkavalli K, Chandraker M. Learning to reconstruct shape and spatially-varying reflectance from a single image. ACM Trans. on Graphics, 2019, 37(6): 269. [doi: [10.1145/3272127.3275055](https://doi.org/10.1145/3272127.3275055)]
- [9] Nalbach O, Arabadzhyska E, Mehta D, Seidel HP, Ritschel T. Deep shading: Convolutional neural networks for screen space shading. Computer Graphics Forum, 2017, 36(4): 65–78. [doi: [10.1111/cgf.13225](https://doi.org/10.1111/cgf.13225)]
- [10] Tewari A, Fried O, Thies J, Sitzmann V, Lombardi S, Sunkavalli K, Martin-Brualla R, Simon T, Saragih J, Nießner M, Pandey R, Fanello S, Wetzstein G, Zhu JY, Theobalt C, Agrawala M, Shechtman E, Goldman DB, Zollhöfer M. State of the art on neural rendering. Computer Graphics Forum, 2020, 39(2): 701–727. [doi: [10.1111/cgf.14022](https://doi.org/10.1111/cgf.14022)]
- [11] Merzbach S, Klein R. Bonn appearance benchmark. In: Proc. of the Workshop on Material Appearance Modeling (2020). 2020. 21–24. [doi: [10.2312/mam.20201142](https://doi.org/10.2312/mam.20201142)]
- [12] Dror RO, Adelson EH, Willsky AS. Recognition of surface reflectance properties from a single image under unknown real-world illumination. In: Proc. of IEEE Workshop on Identifying Objects Across Variation in Lighting. Cambridge: MIT CSAIL, 2001.
- [13] Gao D, Li X, Dong Y, Peers P, Xu K, Tong X. Deep inverse rendering for high-resolution SVBRDF estimation from an arbitrary number of images. ACM Trans. on Graphics, 2019, 38(4): 134. [doi: [10.1145/3306346.3323042](https://doi.org/10.1145/3306346.3323042)]
- [14] Guo Y, Smith C, Hašan M, Sunkavalli K, Zhao S. MaterialGAN: Reflectance capture using a generative SVBRDF model. ACM Trans. on Graphics, 2020, 39(6): 254. [doi: [10.1145/3414685.3417779](https://doi.org/10.1145/3414685.3417779)]

- [15] Karras T, Laine S, Aittala M, Hellsten J, Lehtinen J, Aila T. Analyzing and improving the image quality of stylegan. In: Proc. of the 2020 IEEE/CVF Conf. on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020. 8107–8116. [doi: [10.1109/CVPR42600.2020.90813](https://doi.org/10.1109/CVPR42600.2020.90813)]
- [16] Aittala M, Aila T, Lehtinen J. Reflectance modeling by neural texture synthesis. ACM Trans. on Graphics, 2016, 35(4): 65. [doi: [10.1145/2897824.2925917](https://doi.org/10.1145/2897824.2925917)]
- [17] Zhao YZ, Wang BB, Xu YN, Zeng Z, Wang L, Holzschuch N. Joint SVBRDF recovery and synthesis from a single image using an unsupervised generative adversarial network. In: Proc. of the 31st Eurographics Symp. on Rendering. London: The Eurographics Association, 2020. 53–66. [doi: [10.2312/sr.20201136](https://doi.org/10.2312/sr.20201136)]
- [18] Deschaintre V, Drettakis G, Bousseau A. Guided fine-tuning for large-scale material transfer. Computer Graphics Forum, 2020, 39(4): 91–105. [doi: [10.1111/cgf.14056](https://doi.org/10.1111/cgf.14056)]
- [19] Zsolnai-Fehér K, Wonka P, Wimmer M. Gaussian material synthesis. ACM Trans. on Graphics, 2018, 37(4): 76. [doi: [10.1145/3197517.3201307](https://doi.org/10.1145/3197517.3201307)]
- [20] Zsolnai-Fehér K, Wonka P, Wimmer M. Photorealistic material editing through direct image manipulation. Computer Graphics Forum, 2020, 39(4): 107–120. [doi: [10.1111/cgf.14057](https://doi.org/10.1111/cgf.14057)]
- [21] Granskog J, Rousselle F, Papas M, Novák J. Compositional neural scene representations for shading inference. ACM Trans. on Graphics, 2020, 39(4): 135. [doi: [10.1145/3386569.3392475](https://doi.org/10.1145/3386569.3392475)]
- [22] Rainer G, Jakob W, Ghosh A, Weyrich T. Neural BTF compression and interpolation. Computer Graphics Forum, 2019, 38(2): 235–244. [doi: [10.1111/cgf.13633](https://doi.org/10.1111/cgf.13633)]
- [23] Rainer G, Ghosh A, Jakob W, Weyrich T. Unified neural encoding of BTFs. Computer Graphics Forum, 2020, 39(2): 167–178. [doi: [10.1111/cgf.13921](https://doi.org/10.1111/cgf.13921)]
- [24] Hu BY, Guo J, Chen YJ, Li MT, Guo YW. DeepBRDF: A deep representation for manipulating measured BRDF. Computer Graphics Forum, 2020, 39(2): 157–166. [doi: [10.1111/cgf.13920](https://doi.org/10.1111/cgf.13920)]
- [25] Kuznetsov A, Hašan M, Xu ZX, Yan LQ, Walter B, Kalantari NK, Marschner S, Ramamoorthi R. Learning generative models for rendering specular microgeometry. ACM Trans. on Graphics, 2019, 38(6): 225. [doi: [10.1145/3355089.3356525](https://doi.org/10.1145/3355089.3356525)]
- [26] Che CQ, Luan FJ, Zhao S, Bala K, Gkioulekas I. Towards learning-based inverse subsurface scattering. In: Proc. of the 2020 IEEE Int'l Conf. on Computational Photography (ICCP). St. Louis: IEEE, 2020. 1–12. [doi: [10.1109/ICCP48838.2020.9105209](https://doi.org/10.1109/ICCP48838.2020.9105209)]
- [27] Currius RR, Dolonius D, Assarsson U, Sintorn E. Spherical Gaussian light-field textures for fast precomputed global illumination. Computer Graphics Forum, 2020, 39(2): 133–146. [doi: [10.1111/cgf.13918](https://doi.org/10.1111/cgf.13918)]
- [28] Xin HG, Zheng SK, Xu K, Yan LQ. Lightweight bilateral convolutional neural networks for interactive single-bounce diffuse indirect illumination. IEEE Trans. on Visualization and Computer Graphics, 2020. [doi: [10.1109/TVCG.2020.3023129](https://doi.org/10.1109/TVCG.2020.3023129)]
- [29] Vorba J, Karlík O, Šík M, Ritschel T, Křivánek J. On-line learning of parametric mixture models for light transport simulation. ACM Trans. on Graphics, 2014, 33(4): 101. [doi: [10.1145/2601097.2601203](https://doi.org/10.1145/2601097.2601203)]
- [30] Herholz S, Elek O, Vorba J, Lensch H, Křivánek J. Product importance sampling for light transport path guiding. Computer Graphics Forum, 2016, 35(6): 67–77. [doi: [10.1111/cgf.12950](https://doi.org/10.1111/cgf.12950)]
- [31] Müller T, McWilliams B, Rousselle F, Gross M, Novák J. Neural importance sampling. ACM Trans. on Graphics, 2019, 38(5): 145. [doi: [10.1145/3341156](https://doi.org/10.1145/3341156)]
- [32] Zheng Q, Zwicker M. Learning to importance sample in primary sample space. Computer Graphics Forum, 2019, 38(2): 169–179. [doi: [10.1111/cgf.13628](https://doi.org/10.1111/cgf.13628)]
- [33] Bako S, Meyer M, DeRose T, Sen P. Offline deep importance sampling for monte carlo path tracing. Computer Graphics Forum, 2019, 38(7): 527–542. [doi: [10.1111/cgf.13858](https://doi.org/10.1111/cgf.13858)]
- [34] Müller T, Gross M, Novák J. Practical path guiding for efficient light-transport simulation. Computer Graphics Forum, 2017, 36(4): 91–100. [doi: [10.1111/cgf.13227](https://doi.org/10.1111/cgf.13227)]
- [35] Deng H, Wang BB, Wang R, Holzschuch N. A practical path guiding method for participating media. Computational Visual Media, 2020, 6(1): 37–51. [doi: [10.1007/s41095-020-0160-1](https://doi.org/10.1007/s41095-020-0160-1)]
- [36] Kettunen M, Härkönen E, Lehtinen J. Deep convolutional reconstruction for gradient-domain rendering. ACM Trans. on Graphics, 2019, 38(4): 126. [doi: [10.1145/3306346.3323038](https://doi.org/10.1145/3306346.3323038)]
- [37] Guo J, Li MT, Li QW, Qiang YT, Hu BY, Guo YW, Yan LQ. GradNet: unsupervised deep screened poisson reconstruction for gradient-domain rendering. ACM Trans. on Graphics, 2019, 38(6): 223. [doi: [10.1145/3355089.3356538](https://doi.org/10.1145/3355089.3356538)]
- [38] Hermosilla P, Maisch S, Ritschel T, Ropinski T. Deep-learning the latent space of light transport. Computer Graphics Forum, 2019, 38(4): 207–217. [doi: [10.1111/cgf.13783](https://doi.org/10.1111/cgf.13783)]

- [39] Huo YC, Wang R, Zheng R, Xu HL, Bao HJ, Yoon SE. Adaptive incident radiance field sampling and reconstruction using deep reinforcement learning. *ACM Trans. on Graphics*, 2020, 39(1): 6. [doi: [10.1145/3368313](https://doi.org/10.1145/3368313)]
- [40] Dahm K, Keller A. Learning light transport the reinforced way. In: Proc. of the ACM SIGGRAPH 2017 Talks. Los Angeles: ACM, 2017. 73. [doi: [10.1145/3084363.3085032](https://doi.org/10.1145/3084363.3085032)]
- [41] Watkins CJCH, Dayan P. Q-learning. *Machine Learning*, 1992, 8(3–4): 279–292. [doi: [10.1007/BF00992698](https://doi.org/10.1007/BF00992698)]
- [42] Crassin C, Neyret F, Sainz M, Green S, Eisemann E. Interactive indirect illumination using voxel cone tracing. *Computer Graphics Forum*, 2011, 30(7): 1921–1930. [doi: [10.1111/j.1467-8659.2011.02063.x](https://doi.org/10.1111/j.1467-8659.2011.02063.x)]
- [43] Kristensen AW, Akenine-Möller T, Jensen HW. Precomputed local radiance transfer for real-time lighting design. *ACM Trans. on Graphics*, 2005, 24(3): 1208–1215. [doi: [10.1145/1073204.1073334](https://doi.org/10.1145/1073204.1073334)]
- [44] Chandrasekhar S. Radiative Transfer. New York: Dover, 1960. 237–266.
- [45] Wang BB, Ge LS, Holzschuch N. Precomputed multiple scattering for rapid light simulation in participating media. *IEEE Trans. on Visualization and Computer Graphics*, 2019, 26(7): 2456–2470. [doi: [10.1109/TVCG.2018.2890466](https://doi.org/10.1109/TVCG.2018.2890466)]
- [46] Wang BB, Holzschuch N. Point-based rendering for homogeneous participating media with refractive boundaries. *IEEE Trans. on Visualization and Computer Graphics*, 2018, 24(10): 2743–2757. [doi: [10.1109/TVCG.2017.2768525](https://doi.org/10.1109/TVCG.2017.2768525)]
- [47] Koerner D, Portsmouth J, Sadlo F, Ertl T, Eberhardt B. Flux-limited diffusion for multiple scattering in participating media. *Computer Graphics Forum*, 2014, 33(6): 178–189. [doi: [10.1111/cgf.12342](https://doi.org/10.1111/cgf.12342)]
- [48] Stam J. Multiple scattering as a diffusion process. In: Proc. of the Eurographics Workshop on Rendering Techniques. Dublin: Springer, 1995. 41–50. [doi: [10.1007/978-3-7091-9430-0\\_5](https://doi.org/10.1007/978-3-7091-9430-0_5)]
- [49] Elek O, Ritschel T, Wilkie A, Seidel H P. Interactive cloud rendering using temporally coherent photon mapping. *Computers & Graphics*, 2012, 36(8): 1109–1118. [doi: [10.1016/j.cag.2012.10.002](https://doi.org/10.1016/j.cag.2012.10.002)]
- [50] Matusik W, Pfister H, Brand M, McMillan L. Efficient isotropic BRDF measurement. In: Proc. of the 14th Eurographics Workshop on Rendering 2003. Switzerland: The Eurographics Association, 2003. 241–316. [doi: [10.2312/EGWR/EGWR03/241-248](https://doi.org/10.2312/EGWR/EGWR03/241-248)]
- [51] Bouthors A, Neyret F, Max N, Bruneton E, Crassin C. Interactive multiple anisotropic scattering in clouds. In: Proc. of the 2008 Symp. on Interactive 3D Graphics and Games. San Francisco: ACM, 2008. 173–182. [doi: [10.1145/1342250.1342277](https://doi.org/10.1145/1342250.1342277)]
- [52] Kallweit S, Müller T, McWilliams B, Gross M, Novák J. Deep scattering: Rendering atmospheric clouds with radiance-predicting neural networks. *ACM Trans. on Graphics*, 2017, 36(6): 231. [doi: [10.1145/3130800.3130880](https://doi.org/10.1145/3130800.3130880)]
- [53] Ge LS, Wang BB, Wang L, Holzschuch N. A compact representation for multiple scattering in participating media using neural networks. In: ACM SIGGRAPH 2018 Talks. Vancouver: ACM, 2018. 16. [doi: [10.1145/3214745.3214758](https://doi.org/10.1145/3214745.3214758)]
- [54] Ge LS, Wang BB, Wang L, Meng XX, Holzschuch N. Interactive simulation of scattering effects in participating media using a neural network model. *IEEE Trans. on Visualization and Computer Graphics*, 2021, 27(7): 3123–3134. [doi: [10.1109/TVCG.2019.2963015](https://doi.org/10.1109/TVCG.2019.2963015)]
- [55] Vicini D, Koltun V, Jakob W. A learned shape-adaptive subsurface scattering model. *ACM Trans. on Graphics*, 2019, 38(4): 127. [doi: [10.1145/3306346.3322974](https://doi.org/10.1145/3306346.3322974)]
- [56] Jarosz W, Donner C, Zwicker M, Jensen HW. Radiance caching for participating media. *ACM Trans. on Graphics*, 2008, 27(1): 7. [doi: [10.1145/1330511.1330518](https://doi.org/10.1145/1330511.1330518)]
- [57] Keller A, Fascione L, Fajardo M, Georgiev I, Christensen P, Hanika J, Eisenacher C, Nichols G. The path tracing revolution in the movie industry. In: Proc. of the ACM SIGGRAPH 2015 Courses. Los Angeles: ACM, 2015. 24. [doi: [10.1145/2776880.2792699](https://doi.org/10.1145/2776880.2792699)]
- [58] Zwicker M, Jarosz W, Lehtinen J, Moon B, Ramamoorthi R, Rousselle F, Sen P, Soler C, Yoon SE. Recent advances in adaptive sampling and reconstruction for monte carlo rendering. *Computer Graphics Forum*, 2015, 34(2): 667–681. [doi: [10.1111/cgf.12592](https://doi.org/10.1111/cgf.12592)]
- [59] Moon B, Carr N, Yoon SE. Adaptive rendering based on weighted local regression. In: Proc. of the ACM SIGGRAPH 2014 Talks. Vancouver: ACM2014. 67. [doi: [10.1145/2614106.2614160](https://doi.org/10.1145/2614106.2614160)]
- [60] Bitterli B, Rousselle F, Moon B, Iglesias-Gutián JA, Adler D, Mitchell K, Jarosz W, Novák J. Nonlinearly weighted first-order regression for denoising monte carlo renderings. *Computer Graphics Forum*, 2016, 35(4): 107–117. [doi: [10.1111/cgf.12954](https://doi.org/10.1111/cgf.12954)]
- [61] Kalantari NK, Bako S, Sen P. A machine learning approach for filtering Monte Carlo noise. *ACM Trans. on Graphics*, 2015, 34(4): 122. [doi: [10.1145/2766977](https://doi.org/10.1145/2766977)]
- [62] Bako S, Vogels T, McWilliams B, Meyer M, Novák J, Harvill A, Sen P, Derose T, Rousselle F. Kernel-predicting convolutional networks for denoising Monte Carlo renderings. *ACM Trans. on Graphics*, 2017, 36(4): 97. [doi: [10.1145/3072959.3073708](https://doi.org/10.1145/3072959.3073708)]
- [63] Vogels T, Rousselle F, McWilliams B, Röthlin G, Harvill A, Adler D, Meyer M, Novák J. Denoising with kernel prediction and asymmetric loss functions. *ACM Trans. on Graphics*, 2018, 37(4): 124. [doi: [10.1145/3197517.3201388](https://doi.org/10.1145/3197517.3201388)]
- [64] Chaitanya CRA, Kaplanyan AS, Schied C, Salvi M, Lefohn A, Nowrouzezahrai D, Aila T. Interactive reconstruction of Monte Carlo

- image sequences using a recurrent denoising autoencoder. ACM Trans. on Graphics, 2017, 36(4): 98. [doi: [10.1145/3072959.3073601](https://doi.org/10.1145/3072959.3073601)]
- [65] Gharbi M, Li TM, Aittala M, Lehtinen J, Durand F. Sample-based Monte Carlo denoising using a kernel-splatting network. ACM Trans. on Graphics, 2019, 38(4): 125. [doi: [10.1145/3306346.3322954](https://doi.org/10.1145/3306346.3322954)]
- [66] Xu B, Zhang JF, Wang R, Xu K, Yang YL, Li C, Tang R. Adversarial Monte Carlo denoising with conditioned auxiliary feature modulation. ACM Trans. on Graphics, 2019, 38(6): 224. [doi: [10.1145/3355089.3356547](https://doi.org/10.1145/3355089.3356547)]
- [67] Kuznetsov A, Kalantari NK, Ramamoorthi R. Deep adaptive sampling for low sample count rendering. Computer Graphics Forum, 2018, 37(4): 35–44. [doi: [10.1111/cgf.13473](https://doi.org/10.1111/cgf.13473)]
- [68] Hasselgren J, Munkberg J, Salvi M, Patney A, Lefohn A. Neural temporal adaptive sampling and denoising. Computer Graphics Forum, 2020, 39(2): 147–155. [doi: [10.1111/cgf.13919](https://doi.org/10.1111/cgf.13919)]
- [69] Lin WH, Wang BB, Wang L, Holzschuch N. A detail preserving neural network model for monte carlo denoising. Computational Visual Media, 2020, 6(2): 157–168. [doi: [10.1007/s41095-020-0167-7](https://doi.org/10.1007/s41095-020-0167-7)]
- [70] Zeng Z, Wang L, Wang BB, Kang CM, Xu YN. Denoising stochastic progressive photon mapping renderings using a multi-residual network. Journal of Computer Science and Technology, 2020, 35(3): 506–521. [doi: [10.1007/s11390-020-0264-1](https://doi.org/10.1007/s11390-020-0264-1)]

#### 附中文参考文献:

- [4] 徐翔, 王璐, 徐延宁, 杨承磊, 孟祥旭. 基于点的全局光照绘制方法综述. 计算机辅助设计与图形学学报, 2019, 31(5): 689–697. [doi: [10.3724/SP.J.1089.2019.17322](https://doi.org/10.3724/SP.J.1089.2019.17322)]



赵烨梓(1996—), 女, 硕士, 主要研究领域为计算机图形学、真实感材质模拟.



朱君秋(1995—), 女, 博士生, 主要研究领域为计算机图形学, 真实感渲染和材质模拟.



王璐(1981—), 女, 博士, 教授, 博士生导师, CCF 专业会员, 主要研究领域为高度真实感绘制.



徐子林(1997—), 男, 硕士生, 主要研究领域为计算机图形学.



徐延宁(1975—), 男, 博士, 副教授, 主要研究领域为计算机图形学.



赵钰(1996—), 女, 硕士生, 主要研究领域为计算机图形学.



曾峥(1995—), 男, 博士生, 主要研究领域为计算机图形学, 真实感渲染和光线追踪.



孟祥旭(1962—), 男, 博士, 教授, 博士生导师, CCF 杰出会员, 主要研究领域为人机交互与虚拟现实.



葛亮昇(1995—), 男, 硕士, 主要研究领域为计算机图形学.