

基于深度学习的绘制

王锐¹ 徐昆² 过洁³

霍宇驰¹ 高端²

¹ 浙江大学

² 清华大学

³ 南京大学

关键词：神经绘制 深度学习 可微绘制

引言

绘制是图形学领域重要的基础研究方向之一。近年来，以深度神经网络为代表的深度学习与绘制技术的结合与发展，成为智能图形技术发展的重要一环。绘制的核心目标是高效地生成三维场景的复杂光影效果。传统的绘制方法通常依赖复杂的着色计算、光路模拟和绘制流程，计算代价高。而将深度学习方法融入绘制中，利用深度学习技术的强大表示能力与广泛适用能力，不仅可以求解传统方法无法解决的难题和提升传统方法的效率，还可以提供新颖的深度学习表达与全新的绘制机制，为我们看待计算机图形学问题带来新视角。本文将从神经绘制、基于深度学习的正向绘制和可微绘制三个方面，介绍基于深度学习的绘制技术的发展、现状和未来展望。

神经绘制

神经绘制是指结合深度学习技术进行高质量的图片绘制或视频合成。神经绘制可以分为采集建模、存储表达与图形绘制三个步骤。采集建模是指对场景进行重建和建模；存储表达是指采集数据的高效

压缩存储算法和适合于图形绘制的高效表达；图形绘制负责完成高真实感图片或视频的生成。如图1所示，一方面，采集建模、存储表达与图形绘制是典型的绘制流程中三个顺次递进的步骤；另一方面，三个步骤相互依赖，共同形成一个有机整体。本文将从这三个方面对神经绘制的相关研究工作进行分类介绍。

材质与几何建模

材质与几何建模是指通过算法对目标场景的若干拍摄图片自动化地重建其材质和几何数据的过程。基于深度学习的材质与几何建模方法可以高效地从数据中自动提取数据先验，实现更加轻量而鲁棒的重建。

在材质建模中，早期的经典逆绘制方法通过对基于大量拍摄的图片进行逆绘制优化来实现材质的重建。该类方法依赖密集的数据采集以及繁琐的人工设计，因而其应用场景受到限制。




图1 神经绘制概览

中国科学技术大学的李潇等人^[1]于2017年提出了基于深度学习的单张图片材质建模方法,可以通过卷积神经网络回归的方法从单张手机拍摄的图片中得到平面物体的材质信息。该方法的核心贡献是提出了一种数据自增强策略,即用少量材质数据和大量无标注图片数据即可完成对神经网络的训练。2018年,法国国家信息与自动化研究所(INRIA)的Valentin Deschaintre等人^[2]构建了一个大规模的复杂材质数据集,并提出了一种将全局特征和卷积神经网络相结合的材质建模方法,大幅提升了基于单张图片的材质建模质量。上述基于神经网络的回归方法虽然可以针对单张图片给出合理的材质预测,但其重建的材质结果往往不够准确,难以满足高质量绘制任务的需求。2019年,清华大学的高端等人^[3]提出了一种深度逆绘制方法,通过在材质数据自编码器网络的特征空间进行逆绘制优化,实现了针对任意数量输入图片的材质建模:当输入单张或者少量图片时,该方法即可给出合理的材质预测,而随着输入图片数量的不断增加,其材质重建结果可以逐渐收敛到接近准确结果。

上述方法均假设物体几何是平面或近似平面,不适用于复杂几何的材质建模。2018年,加州大学圣地亚哥分校(UCSD)的Zhengqin Li等人^[4]提出一种可以从单张手机拍摄图片中同时恢复物体几何与材质的方法。后续,UCSD的Sai Bi等人^[5]提出一种利用多张输入图片进行几何材质协同建模的方法,以解决单张图片信息不足的问题。

数据压缩和深度表达

测量数据的压缩和高质量重建是计算机图形学重要的研究方向。基于深度表达的数据压缩方法可以充分利用绘制数据本身的特性实现更加高效的压缩和更高的重建质量。

在计算机图形学中,基于测量数据的材质模型被广泛应用于高逼真绘制。一个典型的例子是双向纹理函数(Bidirectional Texture Function, BTF),它可以描述光线作用于物体表面的复杂散射行为。BTF可以处理反射、折射、次表面散射、自阴影等

多种复杂的全局光照效果,可以使用BTF描述的典型复杂材质包括纤维、织物以及其他带有复杂微结构的材质。

BTF可以形式化地定义为关于位置、入射方向以及出射方向的6维函数。通常而言,BTF数据的压缩是对除了位置外的其他维度的数据进行压缩,该固定位置的切片通常被称为表观双向反射分布函数(Apparent Bidirectional Reflectance Distribution Function, ABRDF)。传统BTF压缩方法主要采用主成分分析等线性方法,重建结果的质量有限。

伦敦大学学院(UCL)的Gilles Rainer等人^[6]提出一种基于非对称自编码器的BTF压缩方法,大幅提升了压缩效率和重建质量。该方法以整个ABRDF数据切片作为输入,通过编码器网络将其转变为低维特征向量,而解码器网络则针对每个入射方向、出射方向分别进行重建。非对称的自编码器结构有助于在绘制中快速查询某个入射/出射方向正确的结果,而无须将整个ABRDF切片进行重建。后续,Gilles Rainer等人^[7]提出一种统一的BTF压缩框架,该方法不再需要针对每一种BTF材质单独进行网络训练,而是将多种不同的BTF材质数据编码到一个公共的特征空间。2021年,UCSD的Alexandr Kuznetsov等人^[8]提出了一种基于全连接神经网络和深度纹理金字塔的BTF表达NeuMIP,可以高效压缩和表达多尺度的BTF数据。

基于图像的绘制

基于图像的绘制是指从若干场景的拍摄图片中生成该场景在新的视角或者新的光照条件下的重绘制结果。基于深度学习的图像绘制方法可以实现轻量而鲁棒的三维世界数字化重绘制,拓宽了基于图像绘制方法的使用范围和应用前景。

基于图像的绘制的目标是:针对真实世界中的某个复杂场景,数字化地生成该场景在新的视角或光照下的高真实感图像或视频。基于图像的绘制方法无须依赖显式的、精确的场景几何,可以直接利用多张图像来生成新视角/光源下的结果。传统的基于图像的绘制方法往往依赖复杂的专业采集设

备和密集的采样数据,大部分方法仅支持视角的动态变化而不支持光源的动态变化。通过结合深度学习,基于图像的绘制方法一方面可以降低采集条件的复杂性,另一方面可以提升其在新视角/光照下绘制的质量和鲁棒性。




图2 Ben Mildenhall等人提出的NeRF方法示意图^[12]

全新视角生成

全新视角生成的相关工作根据其采用的场景几何表达的不同,可以分为基于体素的方法、基于多平面图片的方法、基于深度纹理的方法以及基于隐式曲面的方法等。

基于体素的方法 最具代表性的工作是麻省理工学院 (MIT) 的 Vincent Sitzmann 等人^[9] 提出的 DeepVoxels 表达。其中,每个体素中存储的是深度特征向量,而非具有明确物理含义的参数。该方法在训练过程中无须三维几何信息作为监督,仅通过二维图片作为监督即可实现三维表达的优化和重建。

基于多平面图片的方法 UCSD 的 Zexiang Xu 等人^[10] 于 2019 年提出一种基于扫描平面体 (plane sweep volume) 结构的方法,将三维场景表达为给定视角下一系列预定义深度平面的集合。该方法可以使用端到端的神经网络从 6 张非常稀疏的输入图片中直接预测新视角下的结果。

基于深度纹理的方法 2019 年,慕尼黑工业大学 (TUM) 的 Justus Thies 等人^[11] 提出一种深度延迟绘制框架,用于高真实感的全新视角生成。该方法使用神经纹理代替传统纹理,其每个纹素中存储的是可学习的高维向量,而不是具有明确物理含义的颜色或方向等纹理,而绘制引擎则使用可学习的深度绘制网络实现。

基于隐式表达的方法 最具代表性的工作是 2020 年加利福尼亚大学伯克利分校 (UC Berkeley) 的 Ben Mildenhall 等人^[12] 提出的神经辐射场 (Neural Radiance Fields, NeRF) 方法,如图 2 所示。NeRF 是一种采用神经网络建模的隐式三维场景表达,它用一个三维介质表示整个场景,并借助可微分的介质绘制方法实现给定视角下二维图片的绘

制。NeRF 与传统体素表达的重要区别在于,NeRF 是一种隐式的连续表达,使用全连接神经网络而非显式的体素对空间进行表达和存储。NeRF 表达中的参数可以通过经典的逆绘制策略来优化获取。

重光照

2018 年,UCSD 的 Zexiang Xu 等人^[13] 提出了一种端到端的深度重光照方法,支持任意方向光源下的重光照,该方法的主要优势在于支持基于稀疏输入图片 (仅需 5 张图片) 的高质量重光照结果合成。2020 年,清华大学的高端等人^[14] 提出深度延迟光照框架,仅需用轻量级拍摄设备得到的无结构化图像,即可实现 360 度自由视点重光照。该方法还提出了光照自增强策略以支持多种不同类型的光源。此外,谷歌 (Google) 的 Pratul P. Srinivasan 等人^[15] 通过将 NeRF 表达中的神经辐射场扩展为神经反射场和可见性场,以显式地将材质和光照信息进行解耦,从而实现环境光照下的重光照。

基于深度学习的正向绘制

传统真实感绘制图像的正向绘制过程中主要使用蒙特卡洛 (Monte Carlo, MC) 积分方法,通过生成大量采样光线估计场景的实际亮度。在使用蒙特卡洛积分时,必须平衡估计偏差和方差,否则在采样数量不足时,会导致绘制结果包含严重噪声。如何在短时间内生成不含噪声的图像,寻求性能和速度的平衡,是传统绘制技术的主要关注点。近年来,深度学习技术获得了前所未有的关注,并在诸多领域超越了传统算法^[16],绘制领域的前沿研究也积极拥抱这一趋势,利用深度学习技术推动了蒙特卡洛降噪重建等问题的解决。例如,在电影行业,




图3 基于深度学习的前向绘制关注图像绘制、体绘制、时序绘制和光子映射等问题中的采样与重建技术

皮克斯 (Pixar) 公司的 RenderMan 渲染器在《玩具总动员 4》的制作过程中采用了基于深度学习的自适应采样和去噪滤波器^[18];在游戏行业,英伟达 (Nvidia) 公司引入了蒙特卡洛降噪器实时地从低采样输入中生成高质量图像,以满足实时应用的需求^[19]。

基于深度学习的绘制技术主要通过深度学习技术与传统绘制管线的结合,用神经网络引导采样的分布,或通过神经网络将绘制引擎的中间输出重建为高质量的绘制结果(如图3所示)。本章节总结了基于深度学习的绘制技术的最新进展,将相关研究分为以下三个部分进行讨论。

基本图像域的绘制问题

深度学习技术在绘制领域的一个基本应用场景是,将一些绘制问题作为图像问题处理,并将绘制的中间结果作为图像的输入,通过神经网络将输入映射到期望的图像输出。其中最典型的应用就是使用神经网络对包含蒙特卡洛噪声的绘制引擎输出进行降噪处理,在输入的辅助特征和含噪声图像的帮助下重建单张平滑图像。神经网络将具有噪声的每像素颜色的图像作为输入,通常通过路径追踪估计样本的平均辐射度^[20],并预测相应的平滑图像。由于大多数蒙特卡洛积分方法的样本都可以叠加到图像空间中,因此直接对每像素颜色进行去噪可以作为现有绘制流水线的通用后处理步骤,无须对已有绘制框架进行修改。用神经网络对像素去噪的算法

一经提出,很快就成为学术界和工业界的研究热点。

参数预测法是最早被提出来的一类方法,其核心思想是使用深度学习来预测传统蒙特卡洛滤波器的参数^[21]。文献[21]观察到噪声场景数据与理想滤波器参数之间存在复杂的非线性关系,并提出通过深度学习来学习这种关系,使用各种辅助特征(即

世界坐标、表面法线和纹理值等)作为网络输入,预测非局部均值等滤波器的重建参数,使重建画面与参考画面之间的差异最小化。在运行时,经过训练的网络可以预测新场景的滤波器参数,只需几秒钟即可生成过滤后的图像,在诸如景深、运动模糊、区域照明、光泽反射和全局照明等效果上均优于非深度学习的方法。Xing 等人^[22]还采用参数估计网络来消除路径追踪算法产生的噪声和伪影,采用 Stein 无偏风险估计器来估计指导自适应采样过程的每个像素的噪声水平。

随后,有研究者提出核预测法,通过核预测网络直接预测局部重建核^[22, 24, 25]。为了超越传统滤波器的性能,Bako 等人^[26]提出了一种新颖的监督学习方法,引入基于卷积神经网络 (Convolutional Neural Networks, CNN) 的核预测网络直接估计每像素的局部重建核,用于加权重建领域像素的含噪辐射度获得去噪图像,其结果在精度和速度上较之参数预测法都有明显提升。Vogels 等人^[24]使用非对称损失函数扩展了核预测网络的功能,艺术家可以在使用过程中调整细节丰富程度和平滑度。Back 等人^[27]使用核预测网络来混合像素独立的无偏估计量和像素相关的有偏估计量,降低了蒙特卡洛重建过程中残余的系统误差(如图4所示)。

参数预测和核预测法的一个弱点是带有先验的重建模型假设,因此有时无法与新发展的深度学习技术灵活融合。为了解决这一问题,直接预测法



图4 基于深度学习的蒙特卡洛重建方法通过训练神经网络以预测重建滤波核,可在数秒钟内重建光滑图像^[24]

提出使用深度学习的直接预测蒙特卡洛重建结果方法,即训练神经网络直接预测每个像素的颜色(辐射度)。虽然大多数蒙特卡洛去噪方法依赖均方误差或平均绝对百分比误差作为传统损失函数,但这些优化目标不一定能确保降噪结果符合人的感知。为改进优化目标,Xu等人^[28]提出了一种对抗性的蒙特卡洛去噪方法,使用生成对抗网络(Generative Adversarial Nets, GAN)生成包含更多细节的降噪图像。另一种基于GAN的方法通过向40个皮克斯电影图像帧中添加高斯噪声产生降噪数据集,由于网络不以辅助特征作为输入,训练好的网络还可以对自然照片和CT扫描图像进行去噪^[29]。基于深度残差网络(ResNet)的方法较之普通CNN有显著的性能改进,研究人员训练了一种基于ResNet的无滤波器直接去噪方法去除蒙特卡洛噪声。该方法仅使用三个常见的辅助特征(深度、法线和反照率),降低了现有绘制流水线中的使用成本^[30]。Yang等人^[31, 32]通过引入辅助特征抽取模块去除辅助特征中的冗余信息,从而提升降噪效率。此外,他们提出了一种高动态范围(High-Dynamic Range, HDR)图像归一化方法,以更高效稳定的方式在HDR图像上训练模型^[31]。在后续研究中,他们提出了一种基于自动编码器的双编码器网络结构,首先编码辅助特征作为第二个编码器网络的输入,再由解码器网络重建去噪图像^[32]。然而当采样数不足时,基于深度学习的蒙特卡洛重建结果同样有可靠性不足的问题,Kuznetsov等人^[33]提出联合自适应采样和重建技术的方法解决低采样条件下的蒙特卡洛重建问题。除了重建网络,他们还训练了一个采样重要度估

计网络,以指导像素上的自适应样本分布。

非平凡图像域的绘制问题

因为图像域的几何辅助特征可以从大多数绘制管线中轻松提取,常见的蒙特卡

洛降噪器选择在图像空间上工作,但是光传输的实际物理过程是发生在高维空间中的,如果把高维空间信息映射到退化的二维图像域上,很难保留所有的重要信息。为了解决这个问题,大量研究工作提出在各种非平凡域中解决绘制问题,以保留样本和梯度等重要高维信息,用于高质量绘制和高阶的绘制效果生成。本节讨论使用非平凡域的特征进行单幅图像绘制重建技术。

有别于传统核预测网络使用像素间的采集核(gathering-kernel)重建图像,Gharbi等人^[34]提出了使用样本空间信息的散布核(splatting-kernel)预测网络。他们观察到现有的蒙特卡洛降噪器只用到了像素上的样本统计数据,这必然导致大部分蕴含在样本中的信息丢失,限制了网络重建能力的进一步提升,因而建议使用卷积神经网络预测将单个样本散布到附近像素上的散布核来替代像素间的收集核,除了在常见场景中获得更好的重建效果外,这种基于样本空间的散布核对运动模糊、景深、复杂光传输和低采样等困难绘制场景同样具有性能优势。由于基于样本空间的方法需要像素中的每个样本预测散布核,相较于计算成本很高的图像域方法,Munkberg等人^[35]提出通过数据驱动的方式将样本进行分层聚类后再进行散布核的预测,将原本关于样本数的计算复杂度降到关于层数的复杂度,在计算代价和重建质量之间取得了很好的平衡。此外,Lin等人^[36]根据光路类型对样本进行分类,将样本分解为高频短路径和低频长路径,更好地保留了重建细节。

在已有方法中,诸如表面法向量等图像空间辅助特征对现有蒙特卡洛重建有重要影响,但是光传

播过程中的高维路径空间特征却很难被应用于蒙特卡洛重建中，其关键问题是由于维数灾难导致回归损失函数和高维路径空间特征之间难以形成密集有效的信息流，从而导致在常见的回归学习框架中使用路径空间特征的效率很低。Cho 等人^[37]提出了在路径空间中使用对比流形学习的框架来有效利用路径空间特征，采用弱监督学习的策略从图像域生成密集的路径空间伪标签，使用路径解缠绕的目标函数将路径空间特征镶嵌到低维流形中，用于提升现有蒙特卡洛重建模型的性能。实验结果显示，路径空间信息可以大幅提高已有图像空间或样本空间方法的性能，并能作为额外的流形学习模块应用于已有的回归学习绘制框架中。

光场空间问题是蒙特卡洛绘制的另一个重要研究方向。大多数基于深度学习的蒙特卡洛方法使用像素中样本的平均出射辐射作为特征，而忽略了样本的入射方向信息。Lin 等人^[38]基于局部光场的定义对每像素的局部光场进行分解，通过将局部光场中的光传输操作转为傅里叶光谱上的操作，近似地使用一个协方差矩阵表示为局部光场的傅里叶光谱，并将这个矩阵作为入射光场特征输入到神经网络中以提升蒙特卡洛绘制的质量。此外的一些研究同样使用了光场空间信息，但其目标不是绘制图像的重建，而是直接重建像素上的四维入射辐射场，即每个像素的局部光场，以加速无偏路径引导等无偏绘制算法^[39-41]。

梯度空间的绘制方向的研究发展源自一个核心的重建思想，即图像颜色的重建问题可以利用图像的有限差分梯度在屏幕空间求解一个泊松问题^[42-44]，而梯度域信息通常被认为能更好地捕捉画面在高频区域的变化。近期的一些研究工作将梯度域信息与深度学习技术相结合，使用基于 U-Net 的自动编码器替代泊松求解器来求解梯度域绘制问题^[45]。在另一项独立工作中，南京大学的过洁等人^[46]使用多分支的自动编码器代替泊松求解器，通过端到端学习从含噪输入图像及图像梯度到具有去噪图像的映射，并调整噪声输入和网络输出之间的损失函数，实现了无监督训练。

对于如焦散等很难从视角方向获得有效采样的绘制问题，光子映射^[43, 47]被认为是比路径追踪更高效的算法。光子映射追踪来自光源的大量光子，在每个绘制点处收集光子的贡献，高质量地重建难以从相机追踪的复杂光传输效果。最近的一些绘制研究通过训练深度神经网络来预测核函数，以收集每个绘制点所接收到的光子贡献度^[48]，提升了光子映射算法的效率和质量。文献[48]建议通过神经网络编码光子以减少光子数量，并在着色点收集聚合以进行画面重建。实验结果与已有的光子映射方法相比，提升了焦散效果的绘制质量，并将光子数量减少了一个数量级。此外，Zeng 等人^[49]提出了一种基于深度学习的方法，渐进式地收集随机过程生成的光子，以加速渐进式光子映射算法^[50]。该方法将光子的传输分解为焦散光子和普通光子分别进行重建，并为光子定制了新的辅助特征和多层残差模块来增强重建性能。

复杂高维空间的绘制问题

虽然通过蒙特卡洛重建技术生成单张图像可以满足基本的绘制需求，但是在生活中，常常需要生成更高维度的输出以满足不同的应用。例如，制作计算机动画需要生成时间序列上视觉连贯的多张图像，路径引导算法需要生成每个像素上的四维入射光场以引导数学上无偏的绘制结果。在这些应用场景中，需要针对高维信号的特殊设计和一致约束，才能满足鲁棒性和高效性的要求。本节将基于深度学习的高维绘制问题划分为时序绘制、体绘制和辐射场重建三类，分别进行讨论。

时序绘制是绘制研究中一个极为重要的方向，其目的是生成多张时序连续且视觉连贯的图像，用于生成计算机动画或者实时交互。除了处理速度之外，另一个重要的考虑因素是增强帧之间的视觉连贯性，避免动画中出现闪烁或伪影的低频瑕疵。这一方面的开创性研究使用循环神经网络（Recurrent Neural Network, RNN）显著改善了从稀疏采样输入中生成连续无噪声图像的稳定性^[51]。与单图像的蒙特卡洛重建网络相比，RNN 将过去若干帧

的图像作为神经网络的输入来施加时间序列上的视觉一致性约束,并能更好地利用过去帧上的光照信息生成稳定光滑的图像。Hasselgren 等人^[52]将时序重载与自适应采样技术结合,通过采样预测网络和重建网络在时空域的联合训练以实现在多个连续帧上的高效样本分配,提高了绘制技术在时序




图5 深度学习技术可以极大地提高体绘制速度^[45, 57]

上的鲁棒性和生成图像的保真度,实现了可交互的绘制帧率。Meng 等人^[53]专注提升基于深度学习绘制技术的计算速度,提出将样本从二维图像空间变换到可微三维网格中进行局部降噪滤波,再反射回最终图像的新方法,成功避免了现有算法中使用大感受野(receptive field)卷积核进行蒙特卡洛重建的高昂代价,从而实现了实时帧率的绘制。不同于可交互绘制,Vogels 等人提出的核预测网络^[54]面向动画绘制,因此可以提前知道未来帧,并直接在包含过去帧、当前帧和未来帧的时间窗口上进行蒙特卡洛重建,使用运动矢量来匹配不同时间节点上的像素和特征点,因此不需要使用类似于RNN的循环结构也能生成高质量的连续图像。

体绘制关注呈现光线通过半透明物体产生的复杂视觉效果,包括云、雾、液体、透明固体和医疗数据的可视化等。由于体绘制需要在三维空间中进行,需要计算大量光线传输路径和粒子之间的散射效果,针对这个特点,最近的一些研究使用深度学习技术提升了体绘制的效率。为了高效地绘制云雾,Kallweit 等人^[45]训练了一个具有残差连接的神经网络,通过云中可见性样本点作为输入来预测光线在云中的辐射通量的空间和方向分布,获得较大的性能提升。随后Panin 等人^[55]将神经网络架构分解成一些可以预先计算的部分

和在运行时实时推断的部分,将基于深度学习的云绘制方法的性能提高了2~3倍。Xu 等人^[56]联合梯度域信息和光子映射技术来加速同质透明介质的绘制,采用无监督梯度域深度学习框架进行梯度域体积光子密度估计。在医学成像领域,Hofmann 等人^[57]基于模型位置、世界法线、反射率,以及第一次和第二次散射点的描述信息,以深度学习图像滤波的方式高效地生成用于医学可视化的体积数据绘制(如图5所示)。

常见的蒙特卡洛重建技术无法保证数值上的收敛,因而不适用于对数值精度和视觉保真度敏感的应用程序,例如物理模拟、高真视感训练数据生成和高质量绘制等。最近对辐射场重建的研究将路径引导算法与深度学习进行了结合,用于重建入射光辐射场以引导数学上无偏的路径追踪算法。Bako 等人^[39]使用神经网络预测每像素的重要性采样图,作为引导采样的概率分布函数(Probability Distribution Function, PDF)。有别于现有的在线学习方法,文献[39]采用离线深度学习的策略,可以从大量训练场景中学习先验知识并应用于新场景,避免了繁重的在线学习过程。Huo 等人^[40]提出采用渐进式的自适应采样策略,迭代地使用上一次迭代样本来指导下一次迭代的采样过程。该方法将采样视为可以产生奖励的动作,使用强化学习的策略

来训练质量预测神经网络,以自适应采样并重建四维的入射辐射场,大幅提升了无偏绘制的速度和质量。在文献[58]中,神经网络被用于学习蒙特卡洛采样空间中的采样密度函数,作者通过改进非线性独立成分估计(Non-linear Independent Components Estimation, NICE)技术的性能,生成包含入射光场和材质方程信息的方向采样信息,同样可用于路径引导绘制技术。

可微绘制

众多神经绘制应用和基于深度学习的正向绘制算法都依赖一个可微绘制引擎(或模块),以支持绘制过程中的反向梯度回传。然而,由于绘制过程中存在大量的不连续信号,导致现有的自动梯度计算方法对于大量的绘制过程都失效。因此,针对绘制过程的梯度计算,即可微绘制过程,需要新的技术支持。传统的绘制框架可以分为基于光栅化的绘制和基于物理的真实感绘制两大类。在可微绘制技术中,同样可以根据这两个方向进行分类。

基于光栅化的可微绘制

基于光栅化的绘制一般是指采用某种绘制管线将三维空间的几何物体及其他场景相关信息(材质和光照等)离散化到二维屏幕空间的过程。目前支持可微绘制的技术有相当多一部分是面向光栅化绘制过程。

基于光栅化的可微绘制方向最早的工作是由 Loper 和 Black 提出的 OpenDR^[58]。OpenDR 是一个较为通用的可微绘制引擎,主要由 OpenGL 改进形成,保证了其正向绘制过程不受影响,而反传的梯度则通过光栅化后图像颜色梯度的差分近似计算。由此可见,OpenDR 生成的导数是近似的,精度不高,因此适用范围有限。类似这种用近似方法计算导数的可微绘制技术还有 Kato 等人提出的神经三维网格渲染器(Neural 3D Mesh Renderer, N3MR)^[60]和 Chen 等人提出的基于插值光栅化的微分渲染器(DIB-R)^[61]等。




图6 和传统的光栅化相比,Soft Rasterizer的光栅化确定像素点的位置是基于某种概率的,因此生成的边界比较“软”,从而支持边界导数的计算

区别于上述对导数的直接近似计算,另一类针对光栅化绘制引擎计算导数的方式是改进正向绘制过程,使之支持导数的计算。这类方法中最具代表性的工作是软绘制引擎(Soft Rasterizer, SoftRas)^[62]。由于离散化(或者光栅化)过程本身是不可微的,因此 SoftRas 提出将原本离散化的确定性步骤(确定离散化后像素点的位置)用一个随机概率过程近似。这样使得光栅化后二维图像空间的物体边界是比较柔和的“软”边界,从而支持边界处的导数计算(如图6所示)。

上面提到的可微绘制技术主要应用在基于三角形网格的传统光栅化绘制引擎中。除此之外,近年来还涌现出不少针对点云、体素以及隐式表面的可微绘制技术等。基于光栅化的可微绘制技术通常只考虑比较简单的光照形式(如直接光照),而忽略更具有物理真实感的全局光照效果,因此能适用的应用领域有限。目前,这类可微绘制技术主要用在三维物体重建领域,可以支持无监督训练条件下的简单三维物体重建。

基于物理的可微绘制

基于物理的真实感绘制核心是求解绘制方程^[63]。作为一个高度复杂的积分方程,目前最流行的求解方法是基于蒙特卡洛采样的数值积分方法^[64],如路径追踪、双向路径追踪、Metropolis 路径追踪等。




图7 (a)盲目的随机采样造成很多零贡献采样点,从而导致高方差;(b)采用自动微分提供的一阶和二阶导数可以近似当前采样点周围的几何信息,用于指导下一个有效采样点的生成

最早提出基于物理的可微绘制技术的动机是解决如何“智能”地选取随机采样路径,因为传统的真实感绘制方法所生成的图片质量取决于随机采样路径的选取策略。可微绘制所提供的三维场景导数信息能够给蒙特卡洛采样路径的选择提供有益帮助。

MIT的Tzu-Mao Li等人^[65]最早提出用可微绘制中的自动微分技术获取的场景一阶导数和二阶导数来估计绘制点所在三维空间的局部特征。这些局部信息有助于后续采样点的生成,以提高后续采样对积分的贡献,如图7所示。

通常情况下,估计二阶导数以及对其进行操作都比较耗时,会影响三维空间中随机路径搜索的性能。针对这个问题,Fujun Luan等人^[66]近期提出了一种只利用一阶导数的高效采样方法。这个方法受郎之万(Langevin)扩散过程的启发,在采样状态的演化过程中只用到了—阶导数。

以上两种导数驱动的采样方式一般用在马尔可夫链蒙特卡洛技术中,其好处在于自动化和通用性。但是,它们要求场景中的每条采样路径都能计算导数,而这对存在大量不连续边界的三维场景而言有一定的困难。在被积函数(integrand function)存在不连续边界的情况下,需要同时考虑光滑连续区域内的内部导数和不连续处的边界导数,而边界导数处理起来通常比较困难。

在基于物理的可微绘制技术中,目前有两种常见策略可以解决边界导数的计算问题。第一种策略尝试找到所有的不连续边界,并对这些边界进行特定地显式积分来获取绘制方程的导数^[68, 69]。

第二种策略通过重参数化或者散度定理将边界采样转化为面采样,从而回避边界的不连续性对导数计算的影响^[70~72]。

即使对于物体内部的连续区域,直接采用前向绘制过程中的采样技术来估算内部导数,也会在高光或接近镜面的物体表面产生较大的方差。近期,Cheng Zhang等人^[73]提出的对偶抽样(antithetic sampling)技术在一定程度上缓解出了问题,该方法通过在导数估算时引入负相关的采样点来降低方差。

随着基于物理的可微绘制技术的发展,越来越多的真实感绘制算法或者绘制引擎支持自动求导^[74~76],甚至支持参与介质场景的导数计算^[69, 77],这为开发更高效的蒙特卡洛采样技术以及支持更复杂的场景提供了新的途径。除了提升采样效率之外,基于物理的可微绘制技术的另一个广阔的应用领域是逆向绘制(inverse rendering)或场景理解,即通过图片推理出三维场景的几何、材质或者光照等信息。

支持可微绘制的深度学习平台

目前,主流的深度学习平台都在一定程度上支持可微绘制。例如,在PyTorch平台有PyTorch3D^[78]和Kaolin^[79],在TensorFlow平台有TensorFlow Graphics^[80]等。在国产深度学习平台方面,Jittor(计图)平台^[81]的可微绘制库JRender已经支持可微表面绘制和可微体绘制特性。其中可微表面绘制支持N3MR和SoftRas两种算法,且这两个算法在Jittor平台上的绘制速度分别是其在PyTorch上的10.53倍和4.09倍。可微体绘制支持Ray-marching算法,绘制速度是PyTorch版本的1.9~2.3倍(不同数据集)。

总结

随着神经绘制的蓬勃发展,深度学习技术被广泛应用在各种计算机图形学任务当中,展示出极大的发展潜力。本文分析和总结了深度学习和计算机

图形学在不同领域中结合和交叉的方法,从中可以发现,深度学习技术与绘制技术已经进行了不同层次、不同阶段的结合,并且这一结合过程会随着深度学习技术与绘制技术本身的持续发展,变得更加深入。未来基于深度学习的绘制技术会有多种发展方向,例如,深度学习有助于加快传统图形学算法的运行效率或降低传统方法的使用复杂度,未来一定会有更多的图形学问题可以通过深度学习技术实现更加轻量化、高效的解决方案。近年来基于全新深度表达的绘制管线不断涌现,在很多已有任务中展示出可替代传统图形学表达和绘制方法的潜力,如何设计适合特定任务的全新深度表达和绘制流程也是富有挑战且意义重大的研究方向。我们认为,深度学习作为一种通用的数据驱动技术,在与特定计算机图形学问题结合时,仍然依赖研究人员对计算机图形学领域知识的深刻认识,需要将深度学习技术有机地融入到特定的图形学问题中,这是图形学领域研究人员的责任与机会。 ■



王 锐

CCF 专业会员。浙江大学教授。主要研究方向为计算机图形学、实时/真实感绘制、虚拟现实、三维显示技术。
ruiwang@zju.edu.cn



徐 昆

CCF 专业会员。清华大学长聘副教授。主要研究方向为计算机图形学、真实感绘制。
xukun@tsinghua.edu.cn



过 洁

CCF 专业会员。南京大学特任副研究员。主要研究方向为真实感绘制、实时绘制、虚拟现实。
guojie@nju.edu.cn

其他作者: 霍宇驰 高 端

参考文献

- [1] Li X, Dong Y, Peers P, et al. Modeling Surface Appearance from a Single Photograph using Self-augmented Convolutional Neural Networks[J]. *ACM Transactions on Graphics*, 2017, 36(4):1-11.
- [2] Deschaintre V, Aittala M, Durand F, et al. Single-image SVBRDF capture with a rendering-aware deep network[J]. *ACM Transactions on Graphics*, 2018, 37(4).
- [3] Gao D, Li X, Dong Y, et al. Deep inverse rendering for high-resolution SVBRDF estimation from an arbitrary number of images[J]. *ACM Transactions on Graphics*, 2019, 38(4):1-15.
- [4] Zhengqin L I, Zexiang X U, Ramamoorthi R, et al. Learning to Reconstruct Shape and Spatially-Varying Reflectance from a Single Image[J]. *ACM Transactions on Graphics*, 2018, 37(6):269.1-269.11.
- [5] Bi S, Xu Z, Sunkavalli K, et al. Deep 3D Capture: Geometry and Reflectance from Sparse Multi-View Images[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020.
- [6] Gilles, Rainer, Wenzel, et al. Neural BTF Compression and Interpolation[J]. *Computer Graphics Forum: Journal of the European Association for Computer Graphics*, 2019, 38(2):235-244.
- [7] Rainer G, Ghosh A, Jakob W, et al. Unified Neural Encoding of BTFs[J]. *Computer Graphics Forum*, 2020, 39(2):167-178.
- [9] Sitzmann V, Thies J, Heide F, et al. DeepVoxels: Learning Persistent 3D Feature Embeddings[C]// 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2019.
- [10] Xu Z X, Bi S, Sunkavalli K, et al. Deep view synthesis from sparse photometric images[J]. *ACM Transactions on Graphics*, 2019, 38(4).
- [11] Thies J, Zollhfer M, Niener M. Deferred Neural Rendering: Image Synthesis using Neural Textures[J]. *ACM Transactions on Graphics*, 2019..
- [12] Mildenhall B, Srinivasan P P, Tancik M, et al. NeRF: Representing Scenes as Neural Radiance Fields for View Synthesis[C]// *European Conference on Computer Vision*, Cham, 2020.
- [13] Xu Z X, K, Hadap S, et al.. Deep image-based relighting from optimal sparse samples[J]. *ACM Transactions on Graphics*, 2018, 37(4).
- [14] Gao D, Chen G, Dong Y, et al. Deferred Neural Lighting: Free-Viewpoint Relighting from Unstructured Photographs[J]. *ACM Transactions on Graphics*, 39(6), 258:1-258:15, 2020.

- [15]Pratul P Srinivasan, Boyang Deng, Xiuming Zhang, Matthew Tancik, Ben Mildenhall, and Jonathan T Barron. 2021. Nerv: Neural reflectance and visibility fields for relighting and view synthesis. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 7495–7504.
- [16]Y. LeCun, Y. Bengio, and G. Hinton. Deep learning. *nature*, 521(7553):436–444, 2015.
- [17]I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio. Deep learning, volume 1. MIT press Cambridge, 2016. 1
- [18]H. Dahlberg, D. Adler, and J. Newlin. Machine-learning denoising in feature film production. In ACM SIGGRAPH 2019 Talks, pages 1–2. 2019. 1
- [19]C. R. A. Chaitanya, A. S. Kaplanyan, C. Schied, M. Salvi, A. Lefohn, D. Nowrouzezahrai, and T. Aila. Interactive reconstruction of monte carlo image sequences using a recurrent denoising autoencoder. *ACM Transactions on Graphics (TOG)*, 36(4):1–12, 2017. 1, 4
- [20]J. T. Kajiya. The rendering equation. In Proceedings of the 13th annual conference on Computer graphics and interactive techniques, pages 143–150, 1986. 1
- [21]N. K. Kalantari, S. Bako, and P. Sen. A machine learning approach for filtering monte carlo noise. *ACM Trans. Graph.*, 34(4):122–1, 2015. 1
- [22]Q. Xing and C. Chen. Path tracing denoising based on sure adaptive sampling and neural network. *IEEE Access*, 8:116336–116349, 2020.
- [23]S. Bako, T. Vogels, B. McWilliams, M. Meyer, J. Novák, A. Harvill, P. Sen, T. Derose, and F. Rousselle. Kernel-predicting convolutional networks for denoising monte carlo renderings. *ACM Trans. Graph.*, 36(4):97–1, 2017. 2
- [24]T. Vogels, F. Rousselle, B. McWilliams, G. R  thlin, A. Harvill, D. Adler, M. Meyer, and J. Nov  k. Denoising with kernel prediction and asymmetric loss functions. *ACM Transactions on Graphics (TOG)*, 37(4):1–15, 2018.
- [25]M. Gharbi, T.-M. Li, M. Aittala, J. Lehtinen, and F. Durand. Sample-based monte carlo denoising using a kernel- splatting network. *ACM Transactions on Graphics (TOG)*, 38(4):1–12, 2019. 2
- [26]S. Bako, T. Vogels, B. McWilliams, M. Meyer, J. Nov  k, A. Harvill, P. Sen, T. Derose, and F. Rousselle. Kernel-predicting convolutional networks for denoising monte carlo renderings. *ACM Trans. Graph.*, 36(4):97–1, 2017. 2
- [27]J. Back, B.-S. Hua, T. Hachisuka, and B. Moon. Deep combiner for independent and correlated pixel estimates. *ACM Transactions on Graphics (TOG)*, 39(6):1–12, 2020. 2
- [28]B. Xu, J. Zhang, R. Wang, K. Xu, Y.-L. Yang, C. Li, and R. Tang. Adversarial monte carlo denoising with conditioned auxiliary feature modulation. *ACM Trans. Graph.*, 38(6):224–1, 2019. 3
- [29]A. Alsaiani, R. Rustagi, M. M. Thomas, A. G. Forbes, et al. Image denoising using a generative adversarial network. In 2019 IEEE 2nd International Conference on Information and Computer Technologies (ICICT), pages 126–132. IEEE, 2019. 2
- [30]K.-M. Wong and T.-T. Wong. Deep residual learning for denoising monte carlo renderings. *Computational Visual Media*, 5(3):239–255, 2019. 3
- [31]X. Yang, D. Wang, W. Hu, L. Zhao, X. Piao, D. Zhou, Q. Zhang, B. Yin, Q. Cai, and X. Wei. Fast reconstruction for monte carlo rendering using deep convolutional networks. *IEEE Access*, 7:21177–21187, 2018. 3
- [32]X. Yang, D. Wang, W. Hu, L.-J. Zhao, B.-C. Yin, Q. Zhang, X.-P. Wei, and H. Fu. Demc: A deep dual-encoder network for denoising monte carlo rendering. *Journal of Computer Science and Technology*, 34(5):1123–1135, 2019.
- [33]A. Kuznetsov, N. K. Kalantari, and R. Ramamoorthi. Deep adaptive sampling for low sample count rendering. In *Computer Graphics Forum*, volume 37, pages 35–44. Wiley Online Library, 2018. 3
- [34]M. Gharbi, T.-M. Li, M. Aittala, J. Lehtinen, and F. Durand. Sample-based monte carlo denoising using a kernel- splatting network. *ACM Transactions on Graphics (TOG)*, 38(4):1–12, 2019. 2
- [35]J. Munkberg and J. Hasselgren. Neural denoising with layer embeddings. In *Computer Graphics Forum*, volume 39, pages 1–12. Wiley Online Library, 2020. 3
- [36]W. Lin, B. Wang, J. Yang, L. Wang, and L.-Q. Yan. Path-based monte carlo denoising using a three-scale neural network. *Computer Graphics Forum*, n/a(n/a). 3
- [37]I.-Y. CHO, Y. HUO, and S.-E. YOON. Weakly-supervised contrastive learning in path manifold for monte carlo image reconstruction. 2021. 3
- [38]W. Lin, B. Wang, L. Wang, and N. Holzschuch. A detail preserving neural network model for monte carlo denoising.
- [39]S. Bako, M. Meyer, T. DeRose, and P. Sen. Offline deep importance sampling for monte carlo path tracing. In *Computer Graphics Forum*, volume 38, pages 527–542. Wiley Online Library, 2019. 3, 4
- [40]Y. Huo, R. Wang, R. Zheng, H. Xu, H. Bao, and S.-E. Yoon. Adaptive incident radiance field sampling and reconstruction using deep learning. *ACM Transactions on Graphics (TOG)*, 39(1):1–17, 2020. 3, 4
- [41]G. Jiang and B. Kainz. Deep radiance caching: Convolutional autoencoders deeper in ray tracing. *Computers & Graphics*, 94:22–31, 2021. 3

- [42]B.-S. Hua, A. Gruson, V. Petitjean, M. Zwicker, D. Nowrouzezahrai, E. Eisemann, and T. Hachisuka. A survey on gradient-domain rendering. In *Computer Graphics Forum*, volume 38, pages 455–472. Wiley Online Library, 2019. 3
- [43]C.-m. Kang, L. Wang, Y.-n. Xu, and X.-x. Meng. A survey of photon mapping state-of-the-art research and future challenges. *Frontiers of Information Technology & Electronic Engineering*, 17(3):185–199, 2016.
- [44]J. Lehtinen, T. Karras, S. Laine, M. Aittala, F. Durand, and T. Aila. Gradient-domain metropolis light transport. *ACM Transactions on Graphics (TOG)*, 32(4):1–12, 2013.
- [45]S. Kallweit, T. Müller, B. McWilliams, M. Gross, and J. Novák. Deep scattering: Rendering atmospheric clouds with radiance-predicting neural networks. *ACM Transactions on Graphics (TOG)*, 36(6):1–11, 2017. 4
- [46]J. Guo, M. Li, Q. Li, Y. Qiang, B. Hu, Y. Guo, and L.-Q. Yan. Gradnet: unsupervised deep screened poisson reconstruction for gradient-domain rendering. *ACM Transactions on Graphics (TOG)*, 38(6):1–13, 2019. 3
- [47]H. W. Jensen. *Realistic image synthesis using photon mapping*. AK Peters/CRC Press, 2001. 3
- [48]S. Zhu, Z. Xu, H. W. Jensen, H. Su, and R. Ramamoorthi. Deep kernel density estimation for photon mapping. In *Computer Graphics Forum*, volume 39, pages 35–45. Wiley Online Library, 2020.
- [49]Z. Zeng, L. Wang, B.-B. Wang, C.-M. Kang, and Y.-N. Xu. Denoising stochastic progressive photon mapping renderings using a multi-residual network. *Journal of Computer Science and Technology*, 35:506–521, 2020.
- [50]T. Hachisuka, S. Ogaki, and H. W. Jensen. Progressive photon mapping. In *ACM SIGGRAPH Asia 2008 papers*, pages 1–8. 2008. 3
- [51]C. R. A. Chaitanya, A. S. Kaplanyan, C. Schied, M. Salvi, A. Lefohn, D. Nowrouzezahrai, and T. Aila. Interactive reconstruction of monte carlo image sequences using a recurrent denoising autoencoder. *ACM Transactions on Graphics (TOG)*, 36(4):1–12, 2017. 1, 4
- [52]J. Hasselgren, J. Munkberg, M. Salvi, A. Patney, and A. Lefohn. Neural temporal adaptive sampling and denoising.
- [53]X. Meng, Q. Zheng, A. Varshney, G. Singh, and M. Zwicker. Real-time monte carlo denoising with the neural bilateral grid. In C. Dachsbacher and M. Pharr, editors, *Eurographics Symposium on Rendering - DL-only Track*. The Eurographics Association, 2020.
- [54]T. Vogels, F. Rousselle, B. McWilliams, G. Röhlin, A. Harvill, D. Adler, M. Meyer, and J. Novák. Denoising with kernel prediction and asymmetric loss functions. *ACM Transactions on Graphics (TOG)*, 37(4):1–15, 2018.
- [55]M. Panin and S. Nikolenko. Faster rpnn: Rendering clouds with latent space light probes. In *SIGGRAPH Asia 2019 Technical Briefs*, pages 21–24. 2019. 5
- [56]Z. Xu, Q. Sun, L. Wang, Y. Xu, and B. Wang. Unsupervised image reconstruction for gradient-domain volumetric rendering. In *Computer Graphics Forum*, volume 39, pages 193–203. Wiley Online Library, 2020.
- [57]N. Hofmann, J. Martschinke, K. Engel, and M. Stamminger. Neural denoising for path tracing of medical volumetric data. *Proceedings of the ACM on Computer Graphics and Interactive Techniques*, 3(2):1–18, 2020. 4
- [58]T. Müller, B. McWilliams, F. Rousselle, M. Gross, and J. Novák. Neural importance sampling. *ACM Transactions on Graphics (TOG)*, 38(5):1–19, 2019.
- [59]M. M. Loper and M. J. Black. “OpenDR: An approximate differentiable renderer,” in *ECCV*, 2014.
- [60]H. Kato, Y. Ushiku, and T. Harada. “Neural 3D Mesh Renderer,” in *CVPR*, 2018.
- [61]W. Chen, J. Gao, H. Ling, E. Smith, J. Lehtinen, A. Jacobson, and S. Fidler. “Learning to Predict 3D Objects with an Interpolationbased Differentiable Renderer,” in *NeurIPS*, 2019.
- [62]S. Liu, W. Chen, T. Li, and H. Li. “Soft Rasterizer: A Differentiable Renderer for Image-Based 3D Reasoning,” in *ICCV*, 2019.
- [63]James T. Kajiya. 1986. The rendering equation. In *Proceedings of the 13th annual conference on Computer graphics and interactive techniques (SIGGRAPH '86)*. Association for Computing Machinery, New York, NY, USA, 143–150.
- [64]Eric Veach. 1998. Robust monte carlo methods for light transport simulation. Ph.D. Dissertation. Stanford University, Stanford, CA, USA.
- [65]Tzu-Mao Li, Jaakko Lehtinen, Ravi Ramamoorthi, Wenzel Jakob, and Frédo Durand. 2015. Anisotropic Gaussian mutations for metropolis light transport through Hessian-Hamiltonian dynamics. *ACM Trans. Graph.* 34, 6, Article 209 (November 2015), 13 pages.
- [66]Fujun Luan, Shuang Zhao, Kavita Bala, and Ioannis Gkioulekas. 2020. Langevin monte carlo rendering with gradient-based adaptation. *ACM Trans. Graph.* 39, 4, Article 140 (July 2020), 16 pages.
- [67]Shuang Zhao, Wenzel Jakob, Tzu-Mao Li, Physics-Based Differentiable Rendering: A Comprehensive Introduction, *SIGGRAPH 2020 courses*.
- [68]Tzu-Mao Li, Miika Aittala, Frédo Durand, and Jaakko Lehtinen. 2018. Differentiable Monte Carlo ray tracing through edge sampling. *ACM Trans. Graph.* 37, 6, Article 222 (November 2018), 11 pages.

- [69]Cheng Zhang, Lifan Wu, Changxi Zheng, Ioannis Gkioulekas, Ravi Ramamoorthi, and Shuang Zhao. 2019. A differential theory of radiative transfer. *ACM Trans. Graph.* 38, 6, Article 227 (November 2019), 16 pages.
- [70]Guillaume Loubet, Nicolas Holzschuch, and Wenzel Jakob. 2019. Reparameterizing discontinuous integrands for differentiable rendering. *ACM Trans. Graph.* 38, 6, Article 228 (November 2019), 14 pages.
- [71]Cheng Zhang, Bailey Miller, Kai Yan, Ioannis Gkioulekas, and Shuang Zhao. 2020. Path-space differentiable rendering. *ACM Trans. Graph.* 39, 4, Article 143 (July 2020), 19 pages.
- [72]Bangaru, Sai and Li, Tzu-Mao and Durand, Frédo. 2020. Unbiased Warped-Area Sampling for Differentiable Rendering. *SIGGRAPH Asia*.
- [73]Cheng Zhang, Zhao Dong, Michael Doggett, Shuang Zhao, Antithetic Sampling for Monte Carlo Differentiable Rendering, *SIGGRAPH 2021*.
- [74]Merlin Nimier-David, Delio Vicini, Tizian Zeltner, and Wenzel Jakob. 2019. Mitsuba 2: a retargetable forward and inverse renderer. *ACM Trans. Graph.* 38, 6, Article 203 (November 2019), 17 pages.
- [75]Merlin Nimier-David, Sébastien Speierer, Benoît Ruiz, and Wenzel Jakob. 2020. Radiative backpropagation: an adjoint method for lightning-fast differentiable rendering. *SIGGRAPH Asia 2020*.
- [76]Tizian Zeltner, Sébastien Speierer, Iliyan Georgiev, Wenzel Jakob, Monte Carlo Estimators for Differential Light Transport, *SIGGRAPH 2021*.
- [77]Cheng Zhang, Zihan Yu, Shuang Zhao, Path-space differentiable rendering of participating media, *SIGGRAPH 2021*.
- [78]Krishna Murthy J., Edward Smith , Jean-Francois Lafleche, Clement Fuji Tsang, Artem Rozantsev, Wenzheng Chen, Tommy Xiang, Rev Lebedev, and Sanja Fidler, Kaolin: A PyTorch Library for Accelerating 3D Deep Learning Research, <https://arxiv.org/abs/1911.05063>, 2019
- [79]PyTorch3D, <https://pytorch3d.org/>, 2021
- [80]TensorFlow, <https://www.tensorflow.org/graphics>, 2021
- [81]Hu, Shi-Min and Liang, Dun and Yang, Guo-Ye and Yang, Guo-Wei and Zhou, Wen-Yang, Jittor: a novel deep learning framework with meta-operators and unified graph execution, *Science China Information Sciences*, 2020