

三维场景表示的体渲染增强与冗余约束分析

何金旭

重庆交通大学信息科学与工程学院 重庆 400074

摘要: 三维高斯泼溅 (3DGS) 在复杂场景中易产生伪影和细节缺失。为提升重建质量, 本文在早期3DGS框架中引入体渲染计算, 使高斯贡献沿光线连续累积以减轻无序带来的误差; 并结合透射率裁剪剔除冗余椭球, 同时加入多视角一致性约束提高几何稳定性。实验结果显示, 该方法可在多类数据集上有效减少噪声、提升颜色与深度图的可靠性, 具有一定工程应用价值。

关键词: 三维重建; 高斯泼溅; 体渲染; 多视图一致性; 高斯裁剪

近年来, 多视图三维重建技术在虚拟现实、机器人感知和数字场景建模中得到广泛应用。三维高斯泼溅 (3D Gaussian Splatting, 3DGS^[1]) 凭借其显式结构和较高渲染效率表现突出, 但在结构复杂或纹理细碎的场景中

仍容易出现伪影、几何不连续等问题。为进一步提升重建质量, 本文在早期3DGS框架基础上引入体渲染思想, 并结合高斯裁剪和多视角约束, 对原方法进行轻量化优化, 如图1所示。

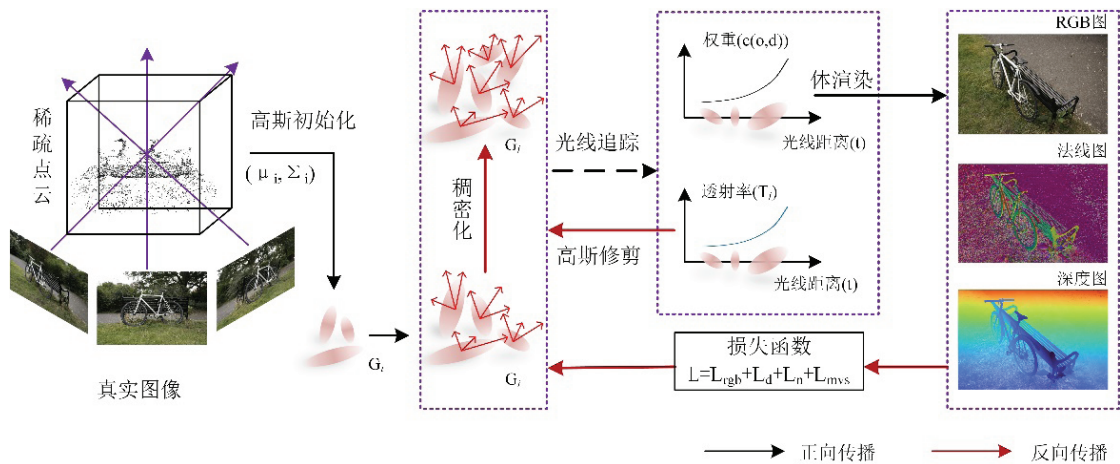


图1 整体框架

一、基于光线累积的体渲染

传统3DGS依赖泼溅投影 (splatting) 完成渲染, 将椭球投影至图像平面并根据深度排序进行颜色混合。由于椭球在三维空间中的分布往往具有不规则性, 多数场景中会出现椭球相互交叉、局部过度堆叠等情况, 使得投影顺序难以保持稳定。一旦排序出现偏差, 容易在图像边缘、纹理突变区域形成明显伪影。例如, 细小结构附近可能产生颜色泄漏, 物体轮廓也会出现柔化甚至断裂, 影响几何精度与渲染可信度。

为缓解上述问题, 本文在早期3DGS框架基础上引入体渲染思路, 将二维平面上的投影叠加改为沿光线方

向的逐点累积。具体做法是, 从相机出发为每个像素发射一条光线, 依次计算光线在不同高斯椭球内的贡献, 并通过累积方式得到最终的颜色值、深度值和法线信息。光线在椭球内部的贡献取决于其位置、椭球形状以及局部密度, 这使渲染过程更接近真实的体积光照模型, 也使高斯之间的前后关系不再完全依赖投影顺序判断。

相比原始泼溅方式, 光线累积具有三个显著优势:

- (1) 更稳定的深度连续性。累积渲染使高斯作用在光线域上更平滑, 减少相邻像素之间的深度跳变, 改善深度图质量。
- (2) 降低重叠干扰导致的伪影。在复杂结构区域,

多个椭球的贡献会按照物理意义进行加权，而不是依赖粗糙的深度排序，从而显著减轻伪影与颜色错位。

(3) 更友好的法线计算方式。通过沿光线整合局部信息，可以获得更稳定的法线分布，这在后续网格提取过程中尤为重要。

值得注意的是，本文采用的是轻量级体渲染模式，不引入多层感知机 (MLP) 等深度网络，保持与3DGS相近的计算复杂度。在实际实验中，该方式在室内与户外场景中均维持较快的训练速度，表明体渲染并未带来额外的时间负担。

通过引入光线累积机制，3DGS的渲染过程由离散、易受噪声影响的投影模式转变为连续、稳定的体渲染模式，为后续的裁剪与一致性约束提供了更可靠的几何基础。

二、基于透射率的高斯裁剪

在标准3DGS框架中，为了保证场景细节的完整性，通常需要生成大量高斯椭球。然而，随着高斯数量增加，部分椭球在最终渲染中贡献极小甚至成为噪声源，这不仅增加显存消耗，也可能导致渲染结果出现背景漂浮点、深度毛刺等问题。传统裁剪策略一般基于固定不透明度阈值判断是否保留椭球，但在复杂场景中，这种方式容易误删对局部结构有意义的椭球，或保留无效冗余椭球，效果不理想。

本文提出基于透射率的高斯裁剪方法，通过分析每个椭球在光线方向上的透射率分布来评估其贡献大小。透射率低的高斯表示光线几乎无法穿透该椭球，其对最终图像贡献有限，因此可以安全地进行裁剪；透射率高的高斯则保留，用以维护场景主要结构。该方法不仅考虑了椭球的局部几何属性，还综合了多视角信息，使裁剪过程更加鲁棒。

实验表明，透射率裁剪能够显著减少深度噪声和背景漂浮点，同时降低约30%~40%的高斯数量，减轻显存压力，并在一定程度上提升渲染稳定性和几何连续性。与固定阈值策略相比，透射率裁剪在保持细节的同时，更好地平衡了效率与质量，是3DGS在复杂场景下的一种轻量化优化手段。

此外，该裁剪策略与光线累积体渲染相结合时，能够形成闭环优化：体渲染提供了连续的光线贡献分布，透射率裁剪利用这些信息进行选择性保留椭球，从而为后续多视角一致性约束提供了更干净的高斯集合。

三、多视角一致性约束

在多视图三维重建中，单一视角优化往往无法保证

几何和纹理在不同视角下的一致性，尤其在大场景或高复杂度对象中，不同视角之间容易产生几何偏移、颜色不连续或纹理错位。为了提高重建结果的稳定性，本文引入多视角一致性约束，作为对光线累积体渲染和透射率裁剪的补充优化手段。

具体做法包括两个方面：

深度一致性：在相邻视角间，将深度图重投影至参考视角，通过计算像素级深度偏差，对优化目标添加约束，使同一三维点在不同视角下几何位置保持一致。

外观一致性：利用局部颜色块匹配，通过比较各视角下颜色差异，引导椭球颜色调整，使最终渲染在不同角度下呈现更连续的视觉效果。

这种约束不依赖大型神经网络，仅基于已有渲染结果和光线信息，即可实现跨视角的平滑几何与外观优化。结合前两章的改进措施，多视角一致性约束能够进一步抑制深度跳变、颜色漂移及局部伪影，同时增强整体场景的视觉连贯性和工程可用性。

在实际实验中，该约束在室内小场景与大尺度户外场景均显示出良好效果：表面几何更加平滑，纹理细节连续性提升，复杂区域的颜色过渡自然，同时训练时间和显存占用仍维持在可接受范围，体现出方法的轻量化优势。

四、实验结果与分析

本研究包括两个部分：新视角合成和表面重建。因此，我们选择了几个通用的数据集，包括DTU数据集和TnT数据集。在表面重建实验中，我们从室内DTU数据集选取了15个场景，每组场景包含49或64张 1600×1200 分辨率的图片，进行小物体重建实验；从无边界户外场景的TnT数据集中选取6组250至1100张不等的 1920×1080 分辨率多视角图像场景用于新视角合成。

为了进行公平的比较，我们采用了与之前相关工作相同的评估标准。对于新视角合成，我们选用了峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR^[2])、结构相似度指数 (Structural Similarity, SSIM^[3]) 和学习感知图像块相似度 (Learned Perceptual Image Patch Similarity, LPIPS^[4]) 作为评估指标；对于表面重建，采用倒角距离 (Chamfer Distance, CD) 作为评估标准。

(一) 表面重建

我们首先在DTU数据集上对本文方法进行了表面重建质量评估。我们选择了若干具有代表性的重建方法进行比较，包括VolSDF^[5]、NeuS和2DGS^[6]。本方法取得了

0.70的倒角距离，如表1所示。

表1 不同方法在DTU数据集上的倒角距离对比

	VolSDF	NeuS	2DGS	本文方法
倒角距离↓	0.86	0.84	0.80	0.70

(二) 新视角合成

为了评估本文方法在新视角合成任务中的性能，我们在TnT数据集上进行了测试。对比方法包括GOF^[7]、MipNeRF360^[8]和2DGS。

实验结果（见表2）表明，本文方法在在TnT数据集上，PSNR、SSIM和LPIPS分别达到23.18、0.849和0.173，展现了较高的渲染质量。

表2 不同方法在TnT数据集上的渲染指标对比

	2DGS	GOF	MipNeRF360	本文方法
PSNR ↑	22.76	22.35	24.15	23.18
SSIM ↑	0.790	0.812	0.822	0.849
LPIPS ↓	0.218	0.179	0.171	0.173

五、结语与展望

本文方法所需内存以及重建速度有改进空间，通过采用更高效的光线采样策略提高重建速度，优化修剪策略减少重建噪声和内存消耗，使得本方法能够在算力有限的设备上同样实现质量兼备效率的三维重建工作。因此，低内存高效率的重建问题是下一步重点研究的方向。

参考文献

[1] Kerbl B, Kopanas G, Leimkühler T, et al. 3d gaussian splatting for real-time radiance field rendering[J]. ACM Trans. Graph., 2023, 42(4): 139:1–139:14.

[2] Bakurov I, Buzzelli M, Schettini R, et al. Structural similarity index (SSIM) revisited: A data-driven approach[J]. Expert Systems with Applications, 2022, 189: 116087.

[3] Hedman P, Philip J, Price T, et al. Deep blending for free-viewpoint image-based rendering[J]. ACM Transactions on Graphics (ToG), 2018, 37(6): 1–15.

[4] Wang P, Liu L, Liu Y, et al. NeuS: Learning neural implicit surfaces by volume rendering for multi-view reconstruction[C]//Proceedings of the 35th International Conference on Neural Information Processing Systems. Red Hook: ACM, 2021: 2081–2094.

[5] Yariv L, Gu J, Kasten Y, et al. Volume rendering of neural implicit surfaces[J]. Advances in Neural Information Processing Systems, 2021, 34: 4805–4815.

[6] Huang B, Yu Z, Chen A, et al. 2d gaussian splatting for geometrically accurate radiance fields[C]//ACM SIGGRAPH 2024 conference papers. Colorado: ACM, 2024: 1–11.

[7] Yu Z, Sattler T, Geiger A. Gaussian opacity fields: Efficient adaptive surface reconstruction in unbounded scenes[J]. ACM Transactions on Graphics (TOG), 2024, 43(6): 1–13.

[8] Barron J T, Mildenhall B, Verbin D, et al. Mip-nerf 360: Unbounded anti-aliased neural radiance fields[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. New Orleans: IEEE Press, 2022: 5470–5479.