中图法分类号:TP391.4　　**文献标识码**:A　　**文章编号**:1006-8961(2025)10-3289-13

论文引用格式:Cheng L H, Li C H, Hu R Z and Liu L G. 2025. 3D Gaussian splatting model for low-light enhancement. Journal of Image and Graphics, 30(10):3289-3301(程龙昊, 李常颢, 胡瑞珍, 刘利刚. 2025. 面向低光增强的三维高斯泼溅模型. 中国图象图形学报, 30(10):3289-3301)[DOI:10.11834/jig.240598]

面向低光增强的三维高斯泼溅模型

程龙昊[1],李常颢[2],胡瑞珍[3],刘利刚[2*]

1. 中国科学技术大学人工智能与数据科学学院,合肥　230026; 2. 中国科学技术大学数学科学学院,合肥　230026;
3. 深圳大学计算机与软件学院,深圳　518000

摘　要:**目的**　使用低光图像训练神经渲染模型时,无法合成正常光照条件下的新视角图像。且低光照条件下处理目标检测、语义分割等任务时,模型性能会明显下降,面临较大的挑战。此外,现有方法在渲染速度和图像高频细节方面存在不定。针对现有问题,本文提出一种对三维高斯泼溅模型进行低光增强的方法。**方法**　首先利用一个轻量化的光照预测网络将三维高斯泼溅模型中三维高斯分布的颜色属性分解为物体本征颜色和光照两个部分,利用本征颜色渲染得到正常光照场景图像,同时使用多种损失函数从结构和颜色上改善图像质量;为了提高图像中高频细节的清晰度,采用固定几何的优化方案。**结果**　实验在低光场景的新视角合成数据集LOM(low-light & normal-light & over-exposure multi-view dataset)上与主流方法进行了比较,与对比结果中最佳方法相比,峰值信噪比(peak signal-to-noise ratio, PSNR)指标平均提升0.12 dB,结构相似性(structural similarity index, SSIM)指标平均提升1.3%,学习感知图像块相似度(learned perceptual image patch similarity, LPIPS)指标平均提高5.5%,训练时间仅有以往方法的1/5,渲染速度则达到以往方法的1 000倍以上。**结论**　本文方法能够更快地进行训练和渲染,同时也具有更高的图像质量,图像的高频细节和结构更加清晰,并通过全面的对比实验验证了方法的有效性与先进性。

关键词:低光增强;新视角合成(NVS);机器学习;神经渲染;三维高斯泼溅(3D GS)

3D Gaussian splatting model for low-light enhancement

Cheng Longhao[1], Li Changhao[2], Hu Ruizhen[3], Liu Ligang[2*]

1. School of Artificial Intelligence and Data Science, University of Science and Technology of China, Hefei　230026, China;
2. School of Mathematics Sciences, University of Science and Technology of China, Hefei　230026, China;
3. College of Computer Science and Software Engineering, Shenzhen University, Shenzhen　518000, China

Abstract: **Objective** Low-light image enhancement for neural rendering is a critical challenge, especially in the domain of novel view synthesis (NVS), which aims to generate realistic images from new viewpoints based on a set of pre-captured images. When neural rendering models are trained under low-light conditions, they fail to produce high-quality results that resemble images captured under normal lighting. These low-light images introduce problems, particularly in downstream tasks such as object detection and semantic segmentation, due to their degraded quality. Traditional methods for addressing this issue usually struggle to balance rendering speed with the preservation of high-frequency details in the generated images. This research aims to address these limitations by proposing a new method for enhancing low-light images using a 3D Gaussian point cloud splatting model. The goal is to improve the quality of rendered images while significantly reducing

收稿日期:2024-10-16;**修回日期**:2025-02-22;**预印本日期**:2025-03-01

*通信作者:刘利刚　lg_liu@ustc.edu.cn

基金项目:国家自然科学基金项目(62025207)

Supported by: National Natural Science Foundation of China (62025207)

the training and rendering times, which makes the approach suitable for practical applications in real-world scenarios where low-light conditions are common. **Method** The proposed method introduces a low-light enhancement framework based on the 3D Gaussian point cloud splatting model. The model is enhanced by decomposing the color attributes of the 3D Gaussian distributions into intrinsic object color and lighting components. A lightweight lighting prediction network is used to estimate the lighting conditions, which allows for the rendering of images that simulate normal lighting conditions, even when the training data consist solely of low-light images. To further improve image quality, a multi-stage gradient weighting strategy is employed. This implementation helps address noise issues commonly found in low-light images, where image noise is amplified due to insufficient lighting. The multi-stage gradient weighting technique ensures that the noise does not obscure important image details, which leads to clearer results. Moreover, the method uses a fixed geometry optimization scheme to retain high-frequency details in the rendered images. This utilization is crucial because low-light conditions can cause distortions in the image structure, and fixed geometry ensures that the overall image clarity and structure are preserved. The core of the methodology revolves around the combination of color decomposition and geometry optimization, which allows the system to maintain high accuracy in rendering while improving efficiency. **Result** Experiments were conducted using the low-light & normal-light & over-exposure multi-view dataset (LOM) dataset, which consists of low-light scene images and their corresponding normal-light images, and the results were compared with several mainstream methods in the field of neural rendering and low-light enhancement. The evaluation metrics used in the comparison include peak signal-to-noise ratio (PSNR), structural similarity index (SSIM), and learned perceptual image patch similarity (LPIPS). The proposed method outperformed the current state-of-the-art approaches across all metrics. In terms of PSNR, the proposed method achieved a 0.12 dB improvement over the best existing method, which indicates a higher signal-to-noise ratio and thus clearer images. SSIM presented a 1.3% improvement. This result suggests that the structural similarity between the generated images and the ground truth was significantly better. LPIPS, which measures perceptual similarity, improved by 5.5%, which demonstrates that the generated images were closer to human perception of the original scenes. In addition to improvements in image quality, the method also delivered significant gains in computational efficiency. The proposed approach reduced training and rendering times by over tenfold compared with traditional methods. This substantial acceleration is due to the explicit point cloud rendering technique used in the 3D Gaussian point cloud splatting model, which eliminates the need for complex and time-consuming calculations typically required in other neural rendering methods. **Conclusion** The proposed low-light enhancement method based on the 3D Gaussian point cloud splatting model offers a substantial advancement over existing techniques in image quality and computational efficiency. By decomposing the color attributes of the 3D Gaussian distributions into intrinsic object color and lighting components, the method enables the rendering of high-quality images under normal-light conditions, even when the training data consist solely of low-light images. The multi-stage gradient weighting strategy effectively addresses the noise amplification issue common in low-light image processing, while the fixed geometry optimization ensures the preservation of high-frequency details and overall image structure. These innovations contribute to the superior performance of the method in generating high-quality images for NVS under challenging low-light conditions. In terms of performance, the proposed method achieves notable improvements in PSNR, SSIM, and LPIPS compared with the state-of-the-art methods. The capability of the method to produce clearer images with better structural and perceptual quality, as well as its significantly faster training and rendering times, makes it a promising solution for real-time applications in fields such as autonomous driving, virtual reality, and 3D scene reconstruction, where image quality and computational efficiency are highly important. This work demonstrates the effectiveness and superiority of the proposed method in enhancing low-light images for neural rendering. The method is a valuable contribution to the fields of computer vision and image synthesis.

Key words: low light enhancement; novel view synthesis (NVS); machine learning; neural rendering; 3D Gaussian splatting (3D GS)

0 引 言

新视角合成(novel view synthesis,NVS)是计算机视觉领域非常流行的方向,旨在给定同一场景的一组定位图像后从新视角生成真实的场景图像。新视角合成技术已广泛应用于自动驾驶(Yang等,2020)、图像编辑(Liu等,2021)以及数字人类(Liu等,2021)等领域。以神经辐射场(neural radiance filed,NeRF)(Mildenhall等,2021)为代表的神经渲染方法的出现彻底改变了新视角合成领域,得到的新视角图像质量远超之前方法。在人体建模(Peng等,2021)、面部建模(Zhuang等,2022)、头发建模(Rosu等,2022)、同时定位与映射(simultaneous localization and mapping,SLAM)(Li等,2022)和3D内容生成(Cao等,2023)等领域NeRF的表现都非常出色。近期也有许多致力于提高其速度(Chen等,2022)和质量(Barron等,2023)的研究,相比于原始的NeRF有了极大改进,但训练速度和渲染时间仍未实现实时渲染。最近,新的神经渲染方法以基于点的表示(Xu等,2022)实现了比NeRF类型方法更快的渲染速度,从而得到了广泛使用。Kerbl等人(2023)提出三维高斯泼溅方法(3D Gaussian splatting,3D GS),通过纯粹的显式表示和基于三维高斯球的可微光栅化器实现了新视角的实时渲染。然而神经渲染中物体的颜色和场景光照条件是紧密耦合的,渲染得到的图像是固定光照条件下的场景图像。而在真实场景中进行采集的时候,可能会遇到各种具有挑战性的环境,其中最普遍的环境之一为低光条件下的场景数据采集,此时直接利用神经渲染方法进行新视角合成,只能得到低光照下的图像,从而很难恢复物体本身的颜色信息;其次由于低光照片的RGB 3个分量的变化范围明显减小,摄像机的噪声也相对放大,进一步掩盖了场景的细节。

解决神经渲染在低光照条件下遇到的问题的直接思路是首先利用低光图像增强方法对采集的低光图像进行处理后得到预测的正常光照图像,再作为输入进行新视角合成模型的训练。而低光增强作为计算机视觉领域一个长期研究的领域,有着许多成熟的方法。低光增强的传统方法通常依赖于视网膜理论(Land,1986)或直方图均衡(Patel等,2013)。目前,基于深度神经网络(deep neural network,DNN)的方法已成为主流解决方案,一系列利用深度学习的方法相继涌现(黄颖 等,2024;闫晓阳 等,2023;张航和颜佳,2024;赵明华 等,2024;Wei等,2018;Guo等,2020;Ma等,2022;Cui等,2022)。这些方法旨在将欠曝光图像校正为正常光照条件,显示出不错的效果。然而,现有的图像增强方法主要依赖于二维图像空间操作,往往无法充分利用场景的三维几何信息,也无法处理多视角输入。

近年来有一些研究对低光增强和新视角合成的结合进行了研究。Wang等人(2023)利用额外的多层神经网络得到NeRF中粒子的低光增强的参数,对粒子的颜色进行增强,得到正常光照的图像。Zou等人(2024)利用一个无监督的评估器—模拟器结构学习不同曝光条件下图像的特征,并提出一种针对新视角合成的双层优化方法,以协调输入图像的亮度信息并保留其结构和内容的一致性。Cui等人(2024)认为低光产生的原因是场景中存在粒子遮挡原始的NeRF辐射,在体渲染方程中加入额外的遮挡率因子,在渲染时去除额外的遮挡因素就可以得到正常光照条件下的图像。这些方法受限于NeRF训练和渲染的速度,需要数个小时来对单个场景进行训练。此外,Aleth-NeRF额外引入的不发光粒子会影响场景真实的几何表达,导致在高频细节上出现模糊。Ye等人(2024)提出Gaussian-DK用于解决三维高斯泼溅方法在低光条件下性能下降的问题,使用了各向异性的三维高斯分布并设计了一个相机相应模块,实验结果表明在低光条件下仍然能合成出高质量的图像结果。You等人(2024)提出LO-Gaussian,利用三维高斯泼溅进行低光照条件下的场景亮度增强,其思路是将三维高斯泼溅渲染的图像作为正常光照场景图像,之后利用参数控制的全局光照模拟和神经网络训练的局部光照模拟在图像空间内模拟低光照条件,对正常光照场景图像进行处理,得到低光场景下的图像,之后利用正常光照场景图像和低光场景图像进行训练。训练完成后,直接利用三维高斯分布进行渲染即可以得到正常光照条件下的图像。在LO-Gaussian方法中,颜色与光照的解耦实际仍然在图像空间内,没有充分利用三维高斯模型的三维空间特征。

首先,为了解决NeRF类型的方法本身的训练和渲染速度慢的问题,本文使用三维高斯泼溅方法作为三维场景表达的模型。3D GS作为一种新的神

经渲染方法，将NeRF隐式的体渲染扩展到显式的点云渲染，显著提高训练和渲染的速度，同时保持了与NeRF一致或更高的渲染质量。此外，因为Aleth-NeRF额外引入的不发光粒子会影响几何结构，所以本文选择保持三维高斯分布的几何信息，在颜色参数上进行分解，避免额外粒子的影响，保证几何的准确性。尽管如此，对3D GS进行低光增强仍然存在以下困难：3D GS中会根据梯度和可见度对高斯分布进行动态增删，低光场景的图像可见度往往较低，大量需要被保留的高斯球被错误地删除；同时也会对高斯球的位置和尺寸等几何参数产生不利影响，影响渲染出的物体结构；低光照图像中的噪点在增强后会进一步放大噪点的影响，造成画面噪声。为了解决上述困难，本文使用增强图像的梯度进行高斯动态调整，使得在暗光场景下具有低可见度，在正常场景下应该具有高可见度的高斯分布保留下来。

基于上述提到的问题和相应的解决思路，本文提出一种能够使用低光图像对三维高斯进行无监督训练，从而渲染正常光照条件的新视角图像的方法，命名为Enhanced-GS。具体的方法是：将三维高斯泼溅中三维高斯分布的原有颜色属性分解为本征颜色和光照两个部分。利用本征颜色渲染得到正常光照场景图像。在训练过程中利用输入的低光场景图像和增强的正常光照场景图像，并结合一系列无监督的损失函数对三维高斯场景进行训练，在缺失正常光照图像输入的条件下渲染正常光照条件的新视角图像。相比之前的基于NeRF的方法，本文方法在训练时间和渲染速度上得到了极大幅度的提高，在图像渲染结果尤其是高频细节上也有更高的质量。

本文主要贡献包括：1）提出一种对3D GS进行低光增强的方法，通过对颜色和光照强度进行分解，得到正常光照强度下的图像；2）在训练过程中使用固定几何的训练策略，提高图像在高频细节上的质量。

本文在多个数据集上进行实验，与现有方法的比较结果表明，本文方法在图像质量和速度上具有明显的优势。

1 三维高斯泼溅介绍

三维高斯泼溅方法将场景表达为一系列的三维高斯分布，每个高斯分布会额外存储相应的一系列参数。

$$G_i = \{ \boldsymbol{\mu}_i, \boldsymbol{\Sigma}_i, \Lambda_i, \boldsymbol{k}_i \mid i = 1, \cdots, N \} \tag{1}$$

每个三维高斯分布G_i由位置$\boldsymbol{\mu}_i \in \mathbf{R}^3$、三维协方差矩阵$\boldsymbol{\Sigma}_i \in \mathbf{R}^3$、不透明度$\Lambda_i \in \mathbf{R}$和球谐系数$\boldsymbol{k}_i = \{ \boldsymbol{k}_l^m \mid 0 \leqslant l \leqslant L, -l \leqslant m \leqslant l \} \in \mathbf{R}^{(L+1)^2 \times 3}$进行定义。在球谐系数中，每个$\boldsymbol{k}_l^m \in \mathbf{R}^3$是用于计算球谐函数的一个系数，$L$是球谐函数的阶数。因为三维高斯的协方差矩阵类似于描述椭球，所以可以用缩放矩阵$\boldsymbol{S}$和旋转矩阵$\boldsymbol{R}$以及对应的转置矩阵$\boldsymbol{S}^{\mathrm{T}}$和$\boldsymbol{R}^{\mathrm{T}}$表示三维协方差矩阵，即

$$\boldsymbol{\Sigma} = \boldsymbol{R}\boldsymbol{S}\boldsymbol{S}^{\mathrm{T}}\boldsymbol{R}^{\mathrm{T}} \tag{2}$$

在实际中可以将缩放矩阵和旋转矩阵分别存储为一个用于缩放的三维向量$\boldsymbol{s} \in \mathbf{R}^3$和一个用于旋转的四维四元数$\boldsymbol{q} \in \mathbf{R}^3$。因此，在训练中可以独立优化这两个因素，简化三维高斯的学习过程。

给定相机姿态$\boldsymbol{T} = \{\boldsymbol{R}_t, \boldsymbol{t}_t\}$和相机内参矩阵$\boldsymbol{K}$，其中，$\boldsymbol{R}_t$表示相机的旋转矩阵，$\boldsymbol{t}_t$表示相机的位移矩阵。需要将三维高斯点$G$的协方差$\boldsymbol{\Sigma}$和位置$\boldsymbol{\mu}$投影到二维图像平面上得到二维屏幕上的协方差$\boldsymbol{\Sigma}'$和位置$\boldsymbol{\mu}'$进行渲染，即

$$\boldsymbol{\Sigma}' = \boldsymbol{J}\boldsymbol{T}\boldsymbol{\Sigma}\boldsymbol{T}^{\mathrm{T}}\boldsymbol{J}^{\mathrm{T}} \tag{3}$$

$$\boldsymbol{\mu}' = \frac{\boldsymbol{K}\boldsymbol{T}\boldsymbol{\mu}}{D} \tag{4}$$

式中，$\boldsymbol{J}$是投影变换的仿射近似的雅可比矩阵，$\boldsymbol{J}^{\mathrm{T}}$是对应的转置矩阵，$\boldsymbol{T}^{\mathrm{T}}$是相机姿态矩阵$\boldsymbol{T}$的转置，$D$是位置$\boldsymbol{\mu}$在$z$轴上的坐标。

投影后，可以根据高斯分布和该点的不透明度计算混合权重α，具体为

$$\alpha = \Lambda \mathrm{e}^{-\frac{1}{2}\boldsymbol{x}^{\mathrm{T}}\boldsymbol{\Sigma}'^{-1}\boldsymbol{x}} \tag{5}$$

式中，$\boldsymbol{x} \in \mathbf{R}^3$是该点的位置向量，$\boldsymbol{x}^{\mathrm{T}}$是对应的转置后的位置向量。根据球谐函数系数可以计算出高斯分布的颜色$\boldsymbol{c} \in \mathbf{R}^3$，具体为

$$\boldsymbol{c} = \sum_{l=0}^{L} \sum_{m=-l}^{l} \boldsymbol{k}_l^m \boldsymbol{Y}_l^m(\theta, \phi) \tag{6}$$

式中，$\boldsymbol{Y}_l^m$是l阶的第m个球谐函数，θ和ϕ是视角方向向量的角度表示。

根据三维高斯分布的深度顺序从前到后进行混合，可以渲染像素的颜色$\boldsymbol{C} \in \mathbf{R}^3$，具体为

$$\boldsymbol{C} = \sum_{i \in N} \boldsymbol{c}_i \alpha_i \prod_{j=1}^{i-1} (1 - \alpha_i) \tag{7}$$

式中，N是投影到像素上的三维高斯分布的数量。

使用三维高斯泼溅模型进行场景重建，需要给定一系列具有真实相机姿态的场景图像，使用一个可微分的光栅化器，根据预测像素颜色和真实像素颜色之间的差异优化所有参数，将高斯点拟合到目标场景上，在训练完成后就可以渲染出任意视角的图像。

2　方　法

本文的工作是一种无监督地将低光场景增强与三维高斯泼溅方法结合的方法，训练中输入的图像是带有相机位姿的低光场景图像，通过颜色分解和增强，得到具有正常光照的三维高斯分布，从而能够在没有正常光照作为输入的情况下渲染出新视角的正常光照场景。同时根据低光场景下的三维高斯泼溅提出特定的训练策略，达到更好的视觉效果。

2.1　颜色分解

图像低光增强算法通常基于 Retinex 理论（Land，1986），将图像$\boldsymbol{I}$看成反射图像$\boldsymbol{R}_e$和照度图像$\boldsymbol{L}$的合成，即

$$\boldsymbol{I} = \boldsymbol{L} \circ \boldsymbol{R}_e \tag{8}$$

式中，“∘”表示通道间相乘。

反射图像代表图像中物体的本征颜色，照度图像则是包含光照等大量的外界信息，决定图像的动态范围。基于 Retinex 理论的图像增强方法通常使用复杂的卷积网络或注意力机制，致力于将低光图像正确地分解为反射图像和低光照的照度图像。在分解之后，反射图像即可作为预测的正常光照图像，或是对照度图像进行增强后与反射图像合成得到正常光照图像。

原始的三维高斯泼溅方法中，高斯分布内的颜色$\boldsymbol{c}$代表的是场景光照和物体颜色耦合的结果。受 Retinex 理论启发，本文提出将高斯分布的颜色$\boldsymbol{c}$分解为光照部分$\boldsymbol{v}$和高斯点本征颜色的部分$\boldsymbol{r}$的乘积，二者都是包含 RGB 3 个通道的向量。利用本征颜色进行渲染得到的图像即是预测的正常光照图像，而本征颜色和光照相乘后得到的颜色则是暗光条件下的颜色，渲染后得到的图像是低光照图像，用于与输入图像比计算损失函数。

2.2　光照预测网络

为了对高斯分布内的颜色进行合理的分解，并保证三维高斯泼溅模型的速度优势，本文将原本高斯分布中存储的颜色视为本征颜色$\boldsymbol{r}$，额外使用一个多层感知机（multilayer perceptron，MLP）网络作为光照预测网络，预测三维高斯的光照$\boldsymbol{v}$，将本征颜色和预测的光照条件相乘可以得到耦合后的低光场景颜色。这样可以在训练完成后直接利用高斯分布中显式存储的本征颜色渲染得到正常光照图像，无需再次使用光照预测网络，极大地加速了渲染速度。为了充分利用三维高斯分布的参数信息和多视角信息，本文将三维高斯分布的缩放矩阵、旋转矩阵、本征颜色和视角方向拼接一起作为输入。为了提高模型的训练速度，在具体模型设计上使用一个轻量化的 4 层的多层神经网络作为光照预测网络，具体的光照预测网络结构如图 1 所示。

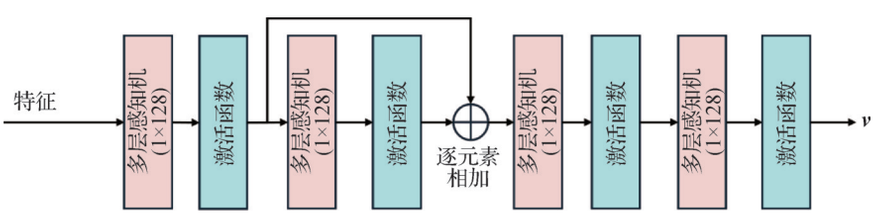

图 1　光照预测网络结构

Fig. 1　Light prediction net structure

本文的计算过程可以表达为

$$\boldsymbol{v}_i = \boldsymbol{F}\left(\boldsymbol{s}_i, \boldsymbol{q}_i, \boldsymbol{r}_i, \boldsymbol{d}_i; \boldsymbol{\Theta}_F\right) \tag{9}$$

$$\tilde{\boldsymbol{c}}_i = \boldsymbol{v}_i \circ \boldsymbol{r}_i \tag{10}$$

式中，$\boldsymbol{F}$是一个 MLP 网络，用于预测光照条件，$\boldsymbol{\Theta}_F$是网络对应的参数，$\boldsymbol{s}_i$、$\boldsymbol{q}_i$、$\boldsymbol{r}_i$ 和 $\boldsymbol{d}_i$是第 i 个三维高斯分布的缩放矩阵、旋转矩阵、利用球谐系数计算的本征颜色和视角方向。$\boldsymbol{v}_i$是预测的光照条件，与本征颜色进行通道间乘法可以得到三维高斯分布对应的低光颜色$\tilde{\boldsymbol{c}}_i$，利用高斯分布的本征颜色和低光颜色，可以分别进行可微光栅化，得到正常光照图像和低光

照图像。具体为

$$\hat{\boldsymbol{C}}=\sum_{i\in N}\boldsymbol{r}_i\alpha_i\prod_{j=1}^{i-1}(1-\alpha_i) \tag{11}$$

$$\tilde{\boldsymbol{C}}=\sum_{i\in N}\tilde{\boldsymbol{c}}_i\alpha_i\prod_{j=1}^{i-1}(1-\alpha_i) \tag{12}$$

式中，$\hat{\boldsymbol{C}}$是正常光照图像对应的像素值，$\tilde{\boldsymbol{C}}$是低光照图像对应的像素值。二者使用相同几何表达的三维高斯分布进行渲染，仅在颜色参数上存在差异。完整的方法流程如图2所示。

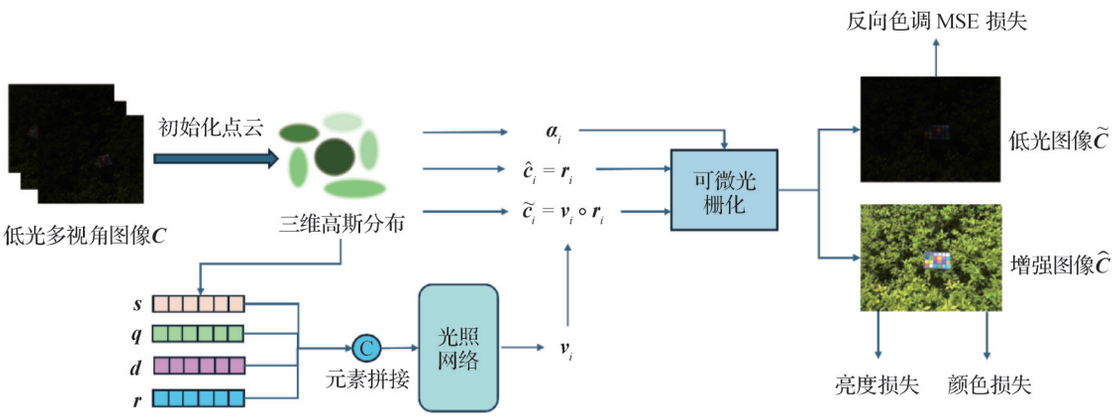

图2　本文方法流程

Fig. 2　The pipeline of our method

图3是分别利用光照强度和本征颜色进行体渲染得到的光强图和本征颜色图，可以看到预测的光照强度与图形几何结构和颜色结构一致，说明了分解光照的有效性。

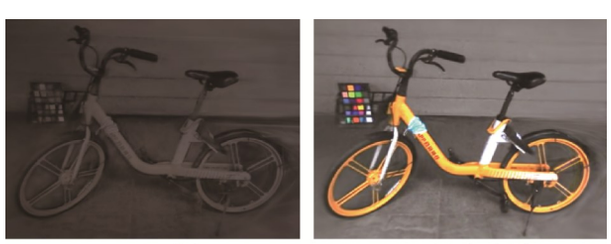

(a) 光强图　(b) 本征颜色图

图3　颜色分解结果图

Fig. 3　Result of color decomposition

((a) light intensity map; (b) intrinsic color map)

2.3　损失函数

本节介绍一系列训练中使用的损失函数，从而实现在低光条件下的新视图合成和图像增强。

2.3.1　反向色调MSE损失

直接在低光场景中使用三维高斯原本的L_1损失函数会导致像素权重的不平衡。像素值低的黑暗像素的贡献偏小，而具有较高像素值的明亮像素会占主导地位，但在低光场景存在大量的黑色像素。为了纠正这种不平衡，从而确保有效地训练三维高斯，本文使用反向色调曲线(Brooks等，2019；Cui等，2021)用于重新调整像素，并使用调整后的像素值计算反向色调MSE(mean square error)损失$L_{\text{it-mse}}$用于三维高斯训练，其计算式为

$$\Phi(x)=\frac{1}{2}-\sin\left(\frac{\sin^{-1}(1-2x)}{3}\right) \tag{13}$$

$$L_{\text{it-mse}}=\frac{1}{B}\sum_{j=1}^{B}\left\|\Phi\left(\boldsymbol{C}(j)\right)-\Phi\left(\tilde{\boldsymbol{C}}(j)\right)\right\|^2 \tag{14}$$

式中，$\Phi(x)$是反向色调曲线函数，$\tilde{\boldsymbol{C}}(j)$和$\boldsymbol{C}(j)$分别是预测的低光场景图像和输入的真实低光场景图像在像素j上的像素值，B是图像尺寸。通过使用这个损失函数，可以更均衡地考虑所有像素的贡献，确保在不同光照条件下的有效训练。

2.3.2　亮度损失

为了调节增强的程度，本文在预测的正常光照图像上使用一个称为全局亮度损失的损失函数L_{exp}。L_{exp}包含一个超参数e，代表预设的增强后的图像亮度。在所有实验中，将e设置为0.45。损失函数计算为

$$L_{\text{exp}}=\frac{1}{B}\sum_{j=1}^{B}\left\|\hat{\boldsymbol{C}}(j)-e\right\|^2 \tag{15}$$

式中，$\hat{\boldsymbol{C}}(j)$是预测的正常光照图像的第j个像素值。通过这个损失函数，可以有效地调节图像增强的程度，确保生成的图像在图像亮度上更符合预期。

2.3.3　颜色损失

在低光条件下拍摄的照片容易丢失颜色信息，增强后得到的图像颜色可能不平衡。假设正常光照图像遵循灰度世界假设，为了规范预测的正常光照图像的颜色，本文引入了颜色平衡损失L_{cc}，计算为

$$L_{cc}=\frac{1}{B}\sum_{j=1}^{B}\sum_{p,q}\left(\hat{\boldsymbol{C}}(j)^{p}-\hat{\boldsymbol{C}}(j)^{q}\right)^{2} \tag{16}$$

式中，$(p,q)\in\{(R,G),(R,B),(G,B)\}$，表示 RGB 3个颜色通道的组合。$\hat{\boldsymbol{C}}(j)^{p}$和$\hat{\boldsymbol{C}}(j)^{q}$分别是预测的正常光照图像的第$j$个像素值在$p$和$q$通道上的值。

最终，整体的训练损失函数L为

$$L=L_{\text{it-mse}}+\lambda_1 L_{\text{exp}}+\lambda_2 L_{cc} \tag{17}$$

式中，λ_1和λ_2是用于调整损失函数幅度的参数。在本文的实验中，λ_1和λ_2分别设置为10^{-3}和10^{-8}。

2.4　固定几何的优化

由于在三维高斯泼溅的优化过程中，会根据三维高斯分布的可见度和梯度大小对三维高斯分布进行动态的删除和增加，在训练前期增强后的正常光照图像，往往不具有合理的视觉效果，使用正常光照图像更新三维高斯分布的几何参数会导致与低光照图像更新的三维高斯分布的几何参数造成冲突，导致三维高斯分布出现不合理的增删，影响图像的高频细节和结构。由于低光照场景实际是由光照不足造成的，正常光照图像应保持和低光图像类似的图像结构。因此，本文在实际的训练过程中，在利用正常光照图像的梯度进行反向传播时，仅对光照预测网络的参数和三维高斯分布的球谐系数等颜色相关的系数进行更新，而使用低光照图像计算的梯度对三维高斯分布的不透明度、旋转矩阵、缩放矩阵和位置等几何相关的参数进行更新。

此外，由于低光图像中的高频细节往往是一个较低的像素值，相邻像素之间的差异较小，较大的尺寸更新幅度会导致一个尺寸大的高斯分布覆盖这些高频细节，在增强后的正常光照图像就会缺少高频细节，为了提高方法在高频细节上的效果，本文在实验中需要减小高斯分布的尺寸更新幅度，在高频细节附近保留尽可能稠密的高斯分布。

3　实验结果

本节首先详细介绍了实验中的训练环境、所用参数和所用的数据集。随后，展示了本文方法与一系列其他研究的指标对比结果。

3.1　数据集和具体实现

本文所采用的方法与单幅图像增强不同，需要对一个场景采集多幅低光图像，在该场景中进行训练，从而进行正常光照的恢复以及新视角合成。目前现有的数据集是 Aleth-NeRF 提出的 LOM（low-light & normal-light & over-exposure multi-view dataset）数据集（Cui 等，2024）和 LLNeRF 中使用的数据集（Wang 等，2023）。LOM 数据集中包含 5 个场景拍摄的低光照图像和对应的正常光照图像。每个场景包括 25～48 幅 375 × 500 像素分辨率的图像，同时包含了在正常光图像上计算得到的相机内参和外参。LLNeRF 数据集包含真实场景拍摄的低光照图像以及相应的相机内外参，光照和阴影条件更加复杂，但缺乏相对应的正常光照图像。

本文方法具体是使用 PyTorch 框架在 Python 中实现的，并扩展了三维高斯泼溅模型的可微光栅化器，以支持增强图像的渲染和梯度计算。三维高斯分布的参数和增强网络分别使用两个独立的 Adam 优化器进行优化。本文使用的模型在单个 NVIDIA RTX 3090 GPU 上训练 30 000 次迭代。

3.2　对比实验

为了证明本文方法的有效性，实验部分比较了不同方法合成正常光照新视角图像的结果。实验结果使用了峰值信噪比（peak signal-to-noise ratio，PSNR）、结构相似性（structural similarity index，SSIM）和学习感知图像块相似度（learned perceptual image patch similarity，LPIPS）作为评估本文方法性能的指标，同时还展示了渲染的正常光照的新视图合成结果，以供定性比较。

首先在实验中使用数据集中的低光图像作为输入，对原始的三维高斯泼溅模型进行训练，将其作为基础方法，命名为 3D GS。在实验中又使用了多个预处理增强方法与三维高斯泼溅结合的方法：首先使用二维图像的低光增强方法对低光图像进行预处理，得到预测的正常光照图像，再使用预测的正常光照图像训练三维高斯泼溅模型，从而能够渲染正常光照条件下的新视角图像。本文使用了目前先进的基于神经网络的二维图像低光增强方法，包括 RetinexNet（Wei 等，2018）、Zero-DCE（zero-reference deep curve estimation）（Guo 等，2020）、SCI（self-

calibrated illumination)(Ma 等, 2022)和 IAT(illumination adaptive Transformer)(Cui 等, 2022)。此外,本文还使用了视频增强方法 LLVE(low light video enhancement)(Zhang 等, 2021),在实验中将这一系列方法命名为 RetinexNet+、Zerodce+、SCI+、IAT+和 LLVE+。同时还与目前已有的基于 NeRF 的无监督的低光增强方法 Aleth-NeRF(Cui 等, 2024)和 AME-NeRF(Zou 等, 2024)进行了比较。在实验过程中发现,Aleth-NeRF 论文中的 LPIPS 指标结果明显较差,这是因为 LPIPS 指标计算依赖于一个神经网络,而 Aleth-NeRF 的网络参数与本文所使用的网络参数不一致,为了保证实验的公平性,实验中将 Aleth-NeRF 的结果重新使用本文的指标计算方式进行计算。新视角合成的定量结果如表 1 所示。

表 1　LOM 数据集上新视角合成的正常光照图像的实验结果

Table 1　Experimental results of novel view synthesis in LOM dataset of normal light conditions

方法	bike	buu	chair	shrub	sofa	平均
	SSIM/PSNR(/dB)/LPIPS	SSIM/PSNR(/dB)/LPIPS	SSIM/PSNR(/dB)/LPIPS	SSIM/PSNR(/dB)/LPIPS	SSIM/PSNR(/dB)/LPIPS	SSIM/PSNR(/dB)/LPIPS
3D GS	0.072/6.37/0.561	0.289/7.51/0.427	0.146/6.04/0.651	0.037/8.07/0.612	0.202/6.26/0.544	0.149/6.85/0.559
IAT+	0.652/13.17/0.381	0.652/14.31/0.317	0.780/17.79/0.464	0.427/13.94/0.395	0.846/17.70/0.341	0.671/15.38/0.379
RetinexNet+	0.722/18.12/0.384	0.735/16.06/0.333	0.764/16.63/0.379	0.395/14.83/0.447	0.837/19.66/0.329	0.690/17.06/0.374
SCI+	0.640/13.61/**0.332**	0.576/7.55/0.545	0.804/19.33/0.383	0.550/17.21/0.383	0.713/10.13/0.370	0.656/13.56/0.402
Zerodce+	0.539/10.50/0.347	0.834/17.74/0.260	0.725/12.46/**0.350**	0.408/12.41/0.390	0.820/14.26/**0.278**	0.665/13.47/0.326
LLVE+	0.661/13.97/0.419	**0.860**/20.04/0.256	0.787/14.98/0.451	0.373/15.42/0.437	**0.865**/17.96/0.360	0.709/16.47/0.384
AME-NeRF	0.732/18.14/0.437	0.854/19.89/0.312	0.751/17.05/0.381	0.462/15.23/0.518	0.847/17.93/0.378	0.729/17.64/0.405
Aleth-NeRF	0.738/20.42/0.432	0.858/20.16/**0.210**	**0.831**/**20.80**/0.359	0.520/**18.25**/0.417	0.860/19.08/0.289	0.761/19.74/0.341
本文	**0.780**/**22.18**/0.340	0.850/**20.78**/0.216	0.805/19.09/0.357	**0.557**/17.33/**0.368**	0.863/**19.94**/0.333	**0.771**/**19.86**/**0.322**

注:加粗、下划线字体表示各列最优、次优结果。

由于原始的三维高斯泼溅方法中的颜色是物体颜色与光照耦合的结果,只能还原训练所使用的低光场景,无法渲染出正常光照的场景图像,因此表现较差,在 3 个指标上的结果都非常差。使用增强方法预处理低光图像的方法会受增强方法的有效性影响,如果场景图像与增强方法训练过程中使用的训练集分布存在较大差异,预处理增强的方法会得到较差的视觉效果。本文方法将增强和重建共同进行,使得高斯的分布更加合理。Aleth-NeRF 作为目前表现最好的模型,由于其引入的额外的不发光粒子会对场景的几何造成影响,在高频细节上会出现模糊的效果。而本文方法采用了颜色解耦的方法,没有引入额外的三维高斯分布对场景几何造成影响,获得了更好的图像结构效果。综合来看,本文方法在大多数场景中获得了最佳或次佳的表现,在平均结果上,本文方法取得了最佳结果。与目前最先进的方法 Aleth-NeRF 相比,在 SSIM 指标上提升了 0.01,在 PSNR 指标上提升了 0.12 dB,在 LPIPS 指标上提升了 0.019,充分证明了本文方法的有效性。

图 4 展示了 IAT、LLVE、Aleth-NeRF 和本文方法在 LOM 数据集上进行新视角合成的结果图像,可以看到,在细节上本文方法的结果更加清晰,保留了图像中的更多细节,充分证明了本文方法的有效性。

在 LLNeRF 数据集中,由于缺乏正常光照图像作为比对,实验使用自然图像质量评估(natural image quality evaluator, NIQE)指标来评估图像是否接近自然图像。实验中使用 IAT、SCI、URetinexNet 和 Zero-DCE 对各个场景的图像进行处理,得到增强结果,对于 Enhanced-GS,使用完整的低光照场景图像作为输入进行训练,训练结束后渲染正常光照场景。NIQE 指标结果对比如表 2 所示,本文方法在平均结果上取得了最佳结果。从图 5 的增强结果可以看到,由于 LLNeRF 数据集中存在大量的图像噪点,其余 4 种方法增强后仍然保留了大量噪点,本文方法在增强的同时有效去除了图像中的噪点。另外,其他方法的颜色较为黯淡,本文方法的颜色更为鲜艳。

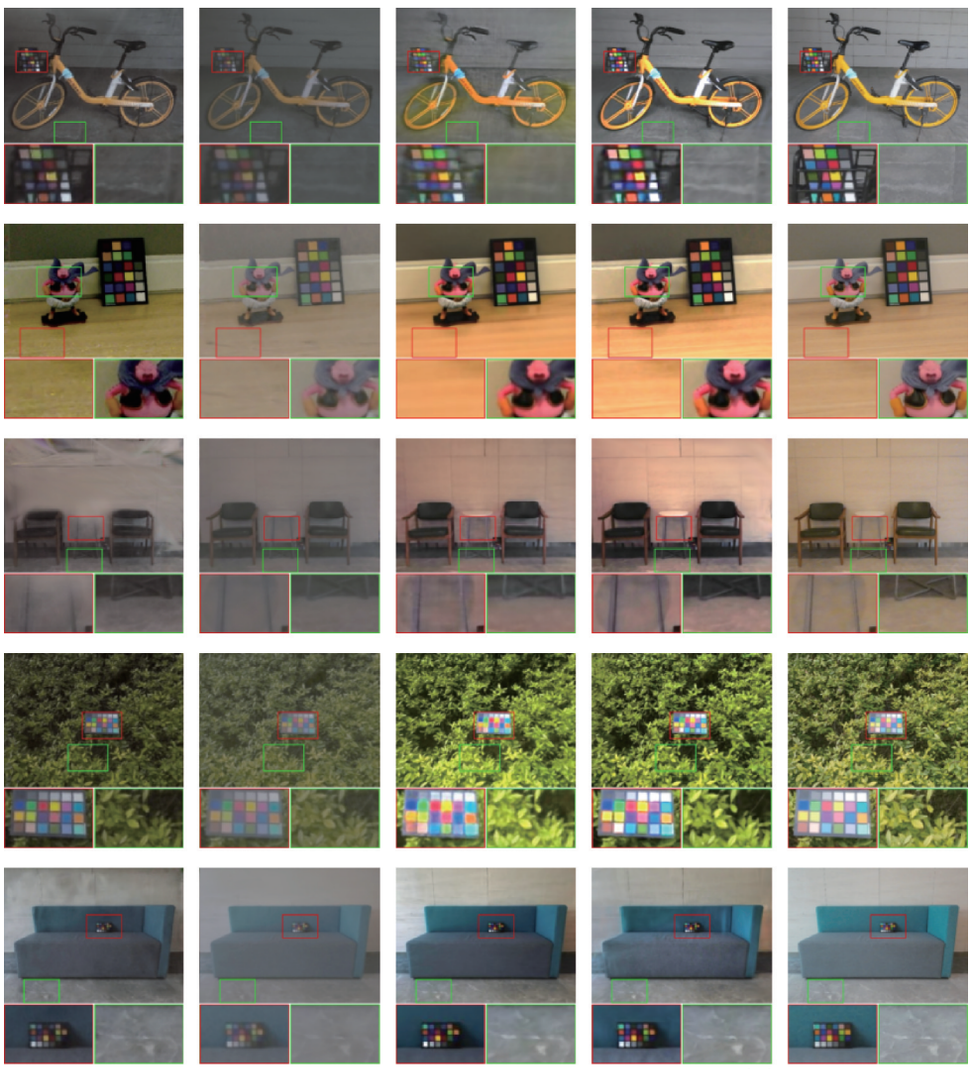

(a) IAT+　(b) LLVE+　(c) Aleth-NeRF　(d) Enhanced-GS (本文)　(e) 真值

图 4　LOM 数据集上新视角合成的正常光照图像结果对比

Fig. 4　Render results of novel view synthesis in normal light condition on LOM dataset

((a) IAT+; (b) LLVE+; (c) Aleth-NeRF; (d) Enhanced-GS(ours); (e) ground truth)

表 2　LLNeRF 数据集上的正常光照图像的 NIQE 结果

Table 2　NIQE results of normal light images in LLNeRF dataset

方法	book	campus-path	Cart	flower	halll	palm	path	Room	Still2	Still3	Still4	Wall	White-chair	平均
SCI	3.32	10.07	11.46	11.96	9.68	10.40	7.57	11.85	13.08	12.47	13.17	14.55	9.02	10.66
IAT	4.99	5.25	4.42	**4.73**	4.36	4.74	5.02	**5.39**	5.33	5.36	5.31	6.72	3.61	5.01
URetinexNet	**3.32**	6.79	5.45	5.86	**3.46**	4.68	5.45	7.58	**5.17**	6.61	6.01	8.72	**3.27**	5.56
Zero-DCE	3.53	10.20	11.90	12.41	10.00	11.12	7.19	12.07	13.86	12.50	13.69	14.22	9.30	10.92
Enhanced-GS(本文)	4.55	**4.38**	**4.33**	6.83	4.47	**4.63**	**3.25**	6.27	6.49	**5.32**	**5.25**	**2.78**	5.61	**4.93**

注:加粗、下划线字体表示各列最优、次优结果。

3.3　性能对比实验

为了比较不同方法的渲染速度和推理速度,实验部分统计了使用单个 RTX 3090 GPU 进行训练和渲染图像的时间。如表 3 所示,得益于三维高斯泼溅的显式点云方法,本文方法在训练时间上取得了明显进步,是 Aleth-NeRF 的 10 倍。同时由于本文采用在高斯分布内直接存储正常光照颜色的方法,避免在渲染正常光照图像时使用 MLP,渲染过程能

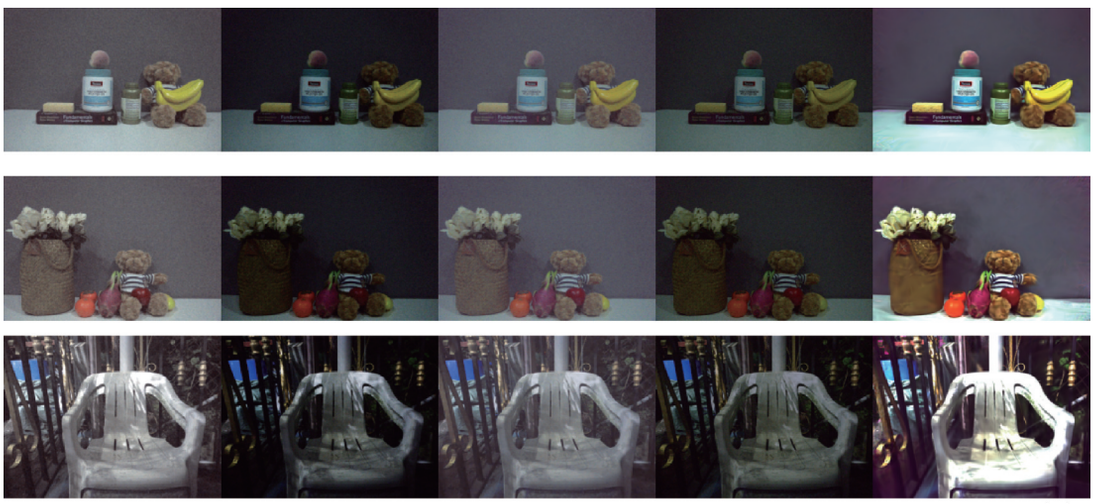

图5　LLNeRF数据集上的实验结果

Fig. 5　Experimental results on LLNeRF dataset ((a) IAT; (b) SCI; (c) URetinexNet; (d) Zero-DCE; (e) Enhanced-GS(ours))

够达到实时渲染速度，而Aleth-NeRF使用固定尺寸的MLP对固定数量的采样点进行推理，只能达到0.22帧/s。

表3　训练和渲染速度对比

Table 3　Comparison of training and rendering speed

方法	训练时长/h	GPU	帧速率/(帧/s)
Aleth-NeRF	6.0	3090Ti×1	0.22
Enhanced-GS	0.5	3090Ti×1	268

3.4　消融实验

3.4.1　损失函数和训练策略的消融实验

为了说明本文方法中所提出的策略和损失函数的有效性，本节设计消融实验并在LOM数据集上进行验证。实验包括：1)去除固定几何的优化策略；2)去除L_{cc}损失函数；3)去除$L_{inv\text{-}mse}$损失函数，使用原始的L_1损失函数；4)去除L_{exp}损失函数；5)完整的模型。

定量实验结果如表4所示。从实验1)和实验5)的对比可以看出，固定几何的优化策略在SSIM、PSNR、LPIPS 3个指标上分别提升0.009、1.01 dB和0.023。说明固定几何的优化策略对改善图像质量的作用显著。实验2)和实验5)的对比结果显示，L_{cc}损失函数的加入对于图像质量有小幅提升。实验3)相比于实验5)，SSIM指标下降了0.009，PSNR指标下降了1.59 dB，LPIPS指标下降了0.021，说明$L_{inv\text{-}mse}$损失函数同样也对图像质量的提升有着显著作用。实验4)和实验5)的结果相比，SSIM指标下降了0.033，PSNR指标下降了3.58 dB，LPIPS指标下降了0.008，图像质量显著下降，说明L_{exp}损失函数对于图像质量影响显著。

不同方法的渲染图像结果如图6所示，从图像中可以看出，固定几何的优化方案改善了图像中的结构模糊现象，在自行车的车把区域，不使用固定几何的优化策略，出现了大片的模糊。L_{cc}损失函数则改善了图像的颜色偏差问题，不使用L_{cc}损失函数导致颜色偏蓝。L_{exp}则会显著影响图像亮度，没有使用L_{exp}损失函数会导致渲染的图像偏暗，无法恢复正常亮度的图像。

3.4.2　颜色损失系数的消融实验

为了说明颜色损失函数的系数λ_2对图像合成质量的影响，本节在LOM数据集上进行消融实验，比较使用不同大小的λ_2进行训练的实验结果。定量结果如表5所示，可以看到，增大λ_2会导致PSNR和SSIM指标显著下降，而对LPIPS指标的影响较小。在实验中发现，λ_2过大会导致图像的亮度降低，因此渲染图像和真实图像的像素值差异较大，导致PSNR和SSIM指标下降明显，而LPIPS指标的计算方法是模仿人类的视觉感知，对像素值的差值相对不敏感，更侧重于图像的整体相似程度，如图7所示，当λ_2为1E−2时，图像明显偏暗，之后随着系数的增大，图像亮度偏向正常。因此由实验结果证明，当λ_2为1E−8时，指标结果最优，图像合成的质量最佳。

表 4　在 LOM 数据集上的消融实验结果

Table 4　Results of ablation experiment on LOM dataset

实验	bike	buu	chair	shrub	sofa	平均
	SSIM/PSNR(/dB)/LPIPS	SSIM/PSNR(/dB)/LPIPS	SSIM/PSNR(/dB)/LPIPS	SSIM/PSNR(/dB)/LPIPS	SSIM/PSNR(/dB)/LPIPS	SSIM/PSNR(/dB)/LPIPS
1)	0.776/20.89/0.355	**0.851**/20.39/0.261	0.795/17.50/0.380	0.534/16.81/0.392	0.858/18.66/0.341	0.762/18.85/0.345
2)	0.750/22.09/0.337	0.849/20.76/0.217	**0.805**/18.98/**0.357**	0.555/17.33/0.365	**0.863**/**19.95**/0.333	0.764/19.82/0.323
3)	0.778/20.96/0.347	0.841/18.63/0.279	0.785/16.57/0.392	0.552/**17.39**/0.373	0.855/17.80/**0.327**	0.762/18.27/0.343
4)	0.746/17.04/0.357	0.825/17.69/**0.203**	0.743/14.03/0.398	**0.557**/17.32/**0.350**	0.822/15.33/0.343	0.738/16.28/0.330
5)	**0.780**/**22.18**/**0.340**	0.850/**20.78**/0.216	**0.805**/**19.09**/**0.357**	**0.557**/17.33/0.368	**0.863**/19.94/0.333	**0.771**/**19.86**/**0.322**

注：加粗字体表示各列最优结果。

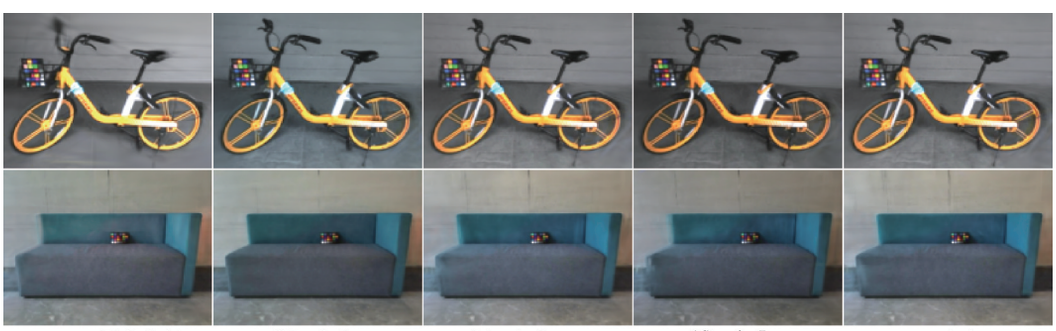

(a) w/o 固定几何　(b) w/o L_{cc}　(c) w/o $L_{inv\text{-}mse}$　(d) w/o L_{exp}　(e) 本文

图 6　消融实验的图像结果

Fig. 6　Images of ablation experiment ((a) w/o fixed geometry; (b) w/o L_{cc}; (c) w/o $L_{inv\text{-}mse}$; (d) w/o L_{exp}; (e) ours)

表 5　在 LOM 数据集上使用不同颜色损失系数的实验结果

Table 5　Experimental results of different color loss factor on LOM dataset

λ_2	SSIM	PSNR/dB	LPIPS
1E−2	0.728	16.64	0.323
1E−4	0.763	19.69	0.321
1E−6	0.765	19.76	0.325
1E−8	0.771	19.86	0.322

(a) λ_2 = 1E−2　(b) λ_2 = 1E−4　(c) λ_2 = 1E−6　(d) λ_2 = 1E−8

图 7　颜色损失使用不同系数进行实验的图像结果

Fig. 7　Images of different factor for color constancy loss ((a) λ_2 = 1E−2; (b) λ_2 = 1E−4; (c) λ_2 = 1E−6; (d) λ_2 = 1E−8)

4　结　论

本文提出一种无监督的对三维高斯泼溅进行低光增强的方法，可以仅根据暗光图像的输入渲染出正常光照强度的新视角图像。首先将三维高斯分布的颜色属性分解为本征颜色与光照分量，实现了正常光照场景和低光照的有效解耦，并为了避免低光与正常光照梯度冲突导致的几何失真，设计了固定几何优化方案，同时通过限制高斯分布尺寸更新幅度，有效保留高频细节。在多个数据集上的实验结果表明，本文方法与现有最优方法相比有更高的图像质量，在图像高频细节上更为清晰，噪点抑制效果显著。此外，本文方法在训练和渲染速度上也有着非常显著的提升。

然而，本文方法仍存在不足之处，首先是由于三维高斯泼溅方法本身的特点，对不同的场景需要进行单独的训练，而且在场景重建过程中，三维高斯泼

溅方法需要大量图像作为输入，稀疏的图像输入会导致场景出现欠拟合的情况，从而导致场景重建出现缺陷区域，如图8(a)所示，在图像的左侧边缘部分存在较为严重的缺陷。同时由于本文从三维高斯分布的层次建模光照强度，在大量噪声的场景中，场景中大量的三维高斯分布可能存在部分三维高斯分布将噪声保留，在体渲染中造成图像噪声，如图8(b)所示，在沙发的主体部分残留较多的噪声。因此，未来的研究工作将探索使用能够利用稀疏输入的三维高斯泼溅模型(Li等，2024)作为基础模型，结合自适应高斯初始化策略，减少对密集输入的依赖，以及在渲染流程中引入噪声感知模块，或结合扩散模型优化高频细节。

(a) 边缘区域缺陷　　(b) 沙发噪声区域

图8　重建效果较差的图像结果

Fig. 8　Image results of poor reconstruction quality

((a) defect in the margin area; (b) noise in the sofa area)

参考文献(References)

Barron J T, Mildenhall B, Verbin D, Srinivasan P P and Hedman P. 2023. Zip-NeRF: anti-aliased grid-based neural radiance fields//Proceedings of 2023 IEEE/CVF International Conference on Computer Vision. Paris, France: IEEE: 19640-19648 [DOI: 10.1109/ICCV51070.2023.01804]

Brooks T, Mildenhall B, Xue T F, Chen J W, Sharlet D and Barron J T. 2019. Unprocessing images for learned raw denoising//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE: 11028-11037 [DOI: 10.1109/CVPR.2019.01129]

Cao Y K, Cao Y P, Han K, Shan Y and Wong K Y K. 2023. DreamAvatar: text-and-shape guided 3D human avatar generation via diffusion models [EB/OL]. [2024-10-16]. https://arxiv.org/pdf/2304.00916.pdf

Chen A P, Xu Z X, Geiger A, Yu J Y and Su H. 2022. TensoRF: tensorial radiance fields//Proceedings of the 17th European Conference on Computer Vision. Tel Aviv, Israel: Springer: 333-350 [DOI: 10.1007/978-3-031-19824-3_20]

Cui Z T, Gu L, Sun X, Ma X Z, Qiao Y and Harada T. 2024. AlethNeRF: illumination adaptive nerf with concealing field assumption//Proceedings of the 38th AAAI Conference on Artificial Intelligence and 36th Conference on Innovative Applications of Artificial Intelligence and 14th Symposium on Educational Advances in Artificial Intelligence. Vancouver, Canada: AAAI: 1435-1444 [DOI: 10.1609/aaai.v38i2.27908]

Cui Z T, Li K C, Gu L, Su S H, Gao P, Jiang Z K, Qiao Y and Harada T. 2022. You only need 90k parameters to adapt light: a light weight transformer for image enhancement and exposure correction//Proceedings of the 33rd British Machine Vision Conference. London, UK: BMVC

Cui Z T, Qi G J, Gu L, You S D, Zhang Z H and Harada T. 2021. Multitask AET with orthogonal tangent regularity for dark object detection//Proceedings of 2021 IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE: 2533-2542 [DOI: 10.1109/ICCV48922.2021.00255]

Guo C L, Li C Y, Guo J C, Loy C C, Hou J H, Kwong S and Cong R M. 2020. Zero-reference deep curve estimation for low-light image enhancement//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 1777-1786 [DOI: 10.1109/CVPR42600.2020.00185]

Huang Y, Peng H, Li C S, Gao S M and Chen F. 2024. LLFlowGAN: a low-light image enhancement method for constraining invertible flow in a generative adversarial manner. Journal of Image and Graphics, 29(1): 65-79 (黄颖, 彭慧, 李昌盛, 高胜美, 陈奉. 2024. LLFlowGAN: 以生成对抗方式约束可逆流的低照度图像增强. 中国图象图形学报, 29(1): 65-79) [DOI: 10.11834/jig.230063]

Kerbl B, Kopanas G, Leimkühler T and Drettakis G. 2023. 3D Gaussian splatting for real-time radiance field rendering. ACM Transactions on Graphics, 42(4): #139 [DOI: 10.1145/3592433]

Land E H. 1986. An alternative technique for the computation of the designator in the retinex theory of color vision. Proceedings of the National Academy of Sciences of the United States of America, 83(10): 3078-3080 [DOI: 10.1073/pnas.83.10.3078]

Li J H, Zhang J W, Bai X, Zheng J, Ning X, Zhou J and Gu L. 2024. DNGaussian: optimizing sparse-view 3D gaussian radiance fields with global-local depth normalization//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 20775-20785 [DOI: 10.1109/CVPR52733.2024.01963]

Li K J, Tang Y S, Prisacariu V A and Torr P H S. 2022. BNV-fusion: dense 3D reconstruction using Bi-level neural volume fusion//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 6156-6165 [DOI: 10.1109/CVPR52688.2022.00607]

Liu L J, Habermann M, Rudnev V, Sarkar K, Gu J T and Theobalt C. 2021. Neural actor: neural free-view synthesis of human actors with pose control. ACM Transactions on Graphics (TOG), 40(6): #219 [DOI: 10.1145/3478513.3480528]

Liu S, Zhang X M, Zhang Z T, Zhang R, Zhu J Y and Russell B. 2021. Editing conditional radiance fields//Proceedings of 2021 IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE: 5753-5763 [DOI: 10.1109/iccv48922.2021.00572]

Ma L, Ma T Y, Liu R S, Fan X and Luo Z X. 2022. Toward fast, flexible, and robust low-light image enhancement//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 5627-5636 [DOI: 10.1109/CVPR52688.2022.00555]

Mildenhall B, Srinivasan P P, Tancik M, Barron J T, Ramamoorthi R and Ng R. 2021. NeRF: representing scenes as neural radiance fields for view synthesis. Communications of the ACM, 65(1): 99-106 [DOI: 10.1145/3503250]

Patel O, Maravi Y P S and Sharma S. 2013. A comparative study of histogram equalization based image enhancement techniques for brightness preservation and contrast enhancement. Signal and Image Processing An International Journal, 4(5): 11-25 [DOI:10.5121/sipij.2013.4502]

Peng S D, Dong J T, Wang Q Q, Zhang S Z, Shuai Q, Zhou X W and Bao H J. 2021. Animatable neural radiance fields for modeling dynamic human bodies//Proceedings of 2021 IEEE/CVF International Conference on Computer Vision. Montreal, Canada: ICCV: 14314-14323 [DOI: 10.1109/ICCV48922.2021.01405]

Rosu R A, Saito S, Wang Z Y, Wu C L, Behnke S and Nam G. 2022. Neural strands: learning hair geometry and appearance from multi-view images//Proceedings of the 17th European Conference on Computer Vision. Tel Aviv, Israel: Springer: 73-89 [DOI: 10.1007/978-3-031-19827-4_5]

Wang H Y, Xu X G, Xu K and Lau R W H. 2023. Lighting up NeRF via unsupervised decomposition and enhancement//Proceedings of 2023 IEEE/CVF International Conference on Computer Vision. Paris, France: IEEE: 12598-12607 [DOI: 10.1109/ICCV51070.2023.01161]

Wei C, Wang W J, Yang W H and Liu J Y. 2018. Deep retinex decomposition for low-light enhancement [EB/OL]. [2024-10-16]. https://arxiv.org/pdf/1808.04560.pdf

Xu Q G, Xu Z X, Philip J, Bi S, Shu Z X, Sunkavalli K and Neumann U. 2022. Point-NeRF: point-based neural radiance fields//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 5428-5438 [DOI: 10.1109/CVPR52688.2022.00536]

Yan X Y, Wang H K, Hou X S and Dun Y J. 2023. Dual-branch low-light image enhancement network via YCbCr space divide-and-conquer. Journal of Image and Graphics, 28(11): 3415-3427 (闫晓阳, 王华珂, 侯兴松, 顿玉洁. 2023. YCbCr空间分治的双分支低照度图像增强网络. 中国图象图形学报, 28(11): 3415-3427) [DOI: 10.11834/jig.221028]

Yang Z P, Chai Y N, Anguelov D, Zhou Y, Sun P, Erhan D, Rafferty S and Kretzschmar H. 2020. SurfelGAN: synthesizing realistic sensor data for autonomous driving//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 11115-11124 [DOI: 10.1109/CVPR42600.2020.01113]

Ye S, Dong Z H, Hu Y B, Wen Y H and Liu Y J. 2024. Gaussian in the dark: real-time view synthesis from inconsistent dark images using gaussian splatting. Computer Graphics Forum, 43(7): #15213 [DOI: 10.1111/cgf.15213]

You J J, Zhang Y Y, Zhou T C, Zhao Y C and Yao L. 2024. LO-Gaussian: Gaussian splatting for low-light and overexposure scenes through simulated filter//Proceedings of 2024 Pacific Graphics Conference Papers and Posters. [s.l.]: The Eurographics Association [DOI: 10.2312/pg.20241301]

Zhang F, Li Y, You S D and Fu Y. 2021. Learning temporal consistency for low light video enhancement from single images//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 4965-4974 [DOI: 10.1109/CVPR46437.2021.00493]

Zhang H and Yan J. 2024. Low-light image enhancement guided by semantic segmentation and HSV color space. Journal of Image and Graphics, 29(4): 966-977 (张航, 颜佳. 2024. 语义分割和HSV色彩空间引导的低光照图像增强. 中国图象图形学报, 29(4): 966-977) [DOI: 10.11834/jig.230182]

Zhao M H, Wen Y C, Du S L, Hu J, Shi C and Li P. 2024. Low-light image enhancement algorithm based on illumination and scene texture attention map. Journal of Image and Graphics, 29(4): 862-874 (赵明华, 汶怡春, 都双丽, 胡静, 石程, 李鹏. 2024. 基于照度与场景纹理注意力图的低光图像增强. 中国图象图形学报, 29(4): 862-874) [DOI: 10.11834/jig.230271]

Zhuang Y Y, Zhu H, Sun X S and Cao X. 2022. MoFaNeRF: morphable facial neural radiance field//Proceedings of the 17th European Conference on Computer Vision. Tel Aviv, Israel: Springer: 268-285 [DOI: 10.1007/978-3-031-20062-5_16]

Zou Y, Li X Y, Jiang Z Y and Liu J Y. 2024. Enhancing neural radiance fields with adaptive multi-exposure fusion: a bilevel optimization approach for novel view synthesis//Proceedings of the 39th AAAI Conference on Artificial Intelligence. Washington, USA: AAAI: 7882-7890 [DOI: 10.1609/aaai.v38i7.28624]

作者简介

程龙昊，男，硕士研究生，主要研究方向为计算机图形学和神经渲染。E-mail: lh_cheng@mail.ustc.edu.cn

刘利刚，通信作者，男，教授，主要研究方向为计算机图形学。E-mail: lg_liu@ustc.edu.cn

李常颢，男，博士研究生，主要研究方向为计算机图形学和三维重建。E-mail: lch0510@mail.ustc.edu.cn

胡瑞珍，女，特聘教授，主要研究方向为计算机图形学。E-mail: ruizhen.hu@gmail.com